

SVEUČILIŠTE U ZAGREBU
FILOZOFSKI FAKULTET
ODSJEK ZA SOCIOLOGIJU

**Predikcijski modeli nezaposlenosti:
empirijski doprinosi**

Diplomski rad

Anja Repalust

Mentorica: doc. dr. sc. Ksenija Klasnić
Komentor: izv. prof. dr. sc. Dragan Bagić

Zagreb, rujan 2018.

Sadržaj

1.	Uvod	1
2.	Ciljevi i svrha rada	5
3.	Teorijski koncept rada	5
3.1.	Nezaposlenost u Hrvatskoj	5
3.2.	Nezaposlenost s obzirom na dob	9
3.3.	Nezaposlenost s obzirom na spol	11
3.4.	Nezaposlenost s obzirom na obrazovanje i zanimanje	13
3.5.	Regionalne razlike u nezaposlenosti	14
3.6.	Nezaposlenost s obzirom na ostale karakteristike	15
4.	Hipoteze.....	16
5.	Metodologija	17
5.1.	Prikupljanje podataka	17
5.2.	Uzorak	17
5.2.1.	Ukupni uzorak	17
5.2.2.	Analizirani uzorak	20
5.3.	Obrada podataka	22
5.4.	Mjerni instrumenti	22
5.4.1.	Zavisna (kriterijska) varijabla: radni status	22
5.4.2.	Nezavisne (prediktorske) varijable.....	22
5.5.	Opis korištenih metoda.....	24
6.	Rezultati.....	26
6.1.	Prva točka mjerenja - 2008.-2010.	26
6.2.	Druga točka mjerenja - 2011.-2013.....	31
6.3.	Treća točka mjerenja - 2014.-2016.....	37
7.	Rasprava	42
7.1.	Ograničenja i naputci za daljnja istraživanja.....	44
8.	Zaključak	45
9.	Literatura	46
10.	Sažetak.....	47

1. Uvod

Međunarodna organizacija rada nezaposlenost definira kao stanje u kojem osoba specifične dobi 1) nema posao (odnosi se na obavljanje plaćenog posla ili samozaposlenje), 2) raspoloživa je krenuti obavljati posao u referentnom periodu (obično 2 tjedna) i 3) traži posao, to jest, poduzima određene korake kako bi se zaposlila ili samozaposlila (Husmanns i dr., 1990).

Kako bi se osobu smatralo nezaposlenom, potrebno je da istovremeno zadovoljava sva tri kriterija. Kriterij „bez posla“ razdvaja nezaposlene od zaposlenih osoba, budući da zaposlene osobe također mogu zadovoljavati kriterij raspoloživosti i traženje posla (Husmanns i dr., 1990). Bitno je napomenuti da se kriterij „bez posla“ odnosi na obavljanje bilo kakvog plaćenog rada u referentnom periodu promatranja, bez obzira na njegovu dužinu trajanja, tako da se osobe koje u trenutku promatranja obavljaju povremeni posao svrstavaju u kategoriju zaposlenih.

Kriterij „traženje posla“ razdvaja nezaposlenost od takozvanih obeshrabljenih radnika – to su osobe bez posla te su raspoložive za rad, međutim, ne poduzimaju radnje u svrhu potencijalnog zaposlenja ili samozaposlenja, jer smatraju da posao ne mogu dobiti (na primjer, starije žene) te samim time se ne smatraju nezaposlenima već ekonomski neaktivnim stanovništvom. Proces traženja posla obuhvaća niz aktivnosti, kao što je: praćenje natječaja, slanje molbi i slično. Prijava u javnu ili privatnu instituciju za traženje posla može se smatrati akcijom traženja posla, ali samo ukoliko je ista poduzeta u svrhu potencijalnog nalaženja posla – ukoliko se osoba prijavljuje samo u svrhu ostvarivanja prava nezaposlenih osoba, prijava se ne može smatrati ispunjavanjem kriterija traženja posla (Husmanns i dr., 1990).

Iako kriterij raspoloživosti pretpostavlja da je osoba, ukoliko se pruži prilika, odmah u mogućnosti krenuti obavljati posao, većinom se uzima određeni vremenski period nakon kojeg bi osoba trebala biti spremna započeti raditi – najčešće je to dva tjedna. Ovime se uzima u obzir mogućnost da je osoba u trenutku ispitivanja bolesna, treba organizirati čuvanje djeteta, organizirati sebi prijevoz do mjesta obavljanja posla i slično. Ipak, ovim kriterijem isključuju se osobe koje su raspoložive tek nakon nekog dužeg perioda (na primjer, studenti nakon završetka studiranja) ili osobe koje trenutno nisu radno sposobne.

Ovi kriteriji odnose se na aktivnosti promatrane osobe i kao takve nemaju polazište u zakonskim odredbama (Kerovec, 1999) te nisu nužno povezani sa statusom osobe u nadležnim institucijama, kao što je Zavod za zapošljavanje. Ipak, u svrhu ostvarivanja prava, nezaposlena

osoba definirana je Člankom 10. Zakona o posredovanju pri zapošljavanju i pravima za vrijeme nezaposlenosti kao „...osoba sposobna ili djelomično sposobna za rad, u dobi od 15 do 65 godina koja nije u radnom odnosu, aktivno traži posao i raspoloživa je za rad...” te ne pripada nekim drugim kategorijama kao što su predsjednici, izvršni direktori i članovi zadruge, vlasnici trgovačkih društva, obrta, djelatnosti poljoprivrede i šumarstva, poljoprivrednici, učenici ili studenti.

Osim samog pojma nezaposlenosti, potrebno je odrediti odnos nezaposlenosti prema ukupnom stanovništvu. Kao što je prikazano na slici 1, ukupno stanovništvo dijeli se na ono radno sposobno te ono koje nije sposobno za rad. Radno sposobnim stanovništvom smatraju se sve osobe između 16 i 65 godina te se ono zatim dijeli na radnu snagu te na neaktivno stanovništvo. Radnu snagu predstavljaju svi oni koji su zaposleni ili nezaposleni, ali aktivno traže posao, dok su neaktivno stanovništvo osobe do navršених 15 godina te svi radno sposobno koji ne spadaju u definiciju radne snage. Postotni udio radne snage u radno sposobnom stanovništvu naziva se stopom aktivnosti, dok je stopa zaposlenosti postotni udio zaposlenih u radno sposobnom stanovništvu.

Ukupno stanovništvo	
Radno sposobno stanovništvo	
Potencijalni radni resursi društva	
Radna snaga / radno aktivno stanovništvo	
Zaposleni	Nezaposleni

Slika 1. Podjela stanovništva prema mogućnosti uključivanja na tržište rada (prema Mrnjevac, 1996)

S obzirom na to da sam apsolutni broj nezaposlenih osoba nije dovoljna mjera, za praćenje nezaposlenosti koristi se stopa nezaposlenosti. Stopa nezaposlenosti označava udio nezaposlenih u aktivnom stanovništvu (radnoj snazi). Ova mjera omogućava nam da pratimo promjene udjela nezaposlenih u stanovništvo kroz različite vremenske periode te između različitih država, gradova ili drugih administrativno podijeljenih područja.

Nezaposlenost se može podijeliti na nekoliko načina. Tradicionalno, ona se prema svojim uzrocima dijeli na normalnu, strukturalnu i cikličnu (Burgess, 1994). Prvi tip, normalna nezaposlenost dodatno se dijeli na frikcijsku i sezonsku. Sezonska nezaposlenost odnosi se na nezaposlenost koja nastaje kao rezultat toga što ponuda i potražnja radne snage ovisi o klimatskim ili drugim uvjetima - na primjer, određene vrste poslova vezane su uz jedno

godišnje doba te se ne mogu obavljati za vrijeme ostalih, što dovodi do veće potražnje za radnom snagom za vrijeme njihovog trajanja (niža stopa nezaposlenosti), a manje za vrijeme ostalih (viša stopa nezaposlenosti) ili to što određeno vremensko razdoblje nosi naglo povećanje ponude radne snage (na primjer, kraj školske godine) bez da istovremeno raste potražnja za njom. Frikcijska nezaposlenost odnosi se na (pretpostavljeno, kratkotrajnu) nezaposlenost koja nastaje zbog kretanja ljudi između dva različita radnih mjesta ili između različitih životnih situacija (završetak školovanja, porod) i radnog mjesta – čak i u uvjetima pune zaposlenosti, potrebno je neko vrijeme (vrijeme traženja) za prelazak na novo radno mjesto nakon napuštanja starog ili nakon porodičnog dopusta te po završetku školovanja.

Drugi tip, strukturalnu nezaposlenosti predstavlja ona nezaposlenost do koje dolazi zbog nepodudaranja između ponude i potražnje za radnicima. To može biti u odnosu na zanimanje, kvalifikacije ili regionalni raspored. Smatra se da do strukturalne nezaposlenosti dolazi zbog bržeg rasta ponude radnika nego što raste potražnja za njima.

Prema tradicionalnoj podjeli nezaposlenosti, strukturalna nezaposlenost gleda se kao fenomen u kojem se paralelno s prevelikom ponudom radnika u jednom području, javlja manjak ponude u nekom drugom području, uz pretpostavku da je samo gospodarstvo sposobno zaposliti svu radnu snagu koja mu je na raspolaganju.

Van tradicionalnog tipa strukturalne nezaposlenosti, pojavljuje se fenomen tzv. „nove“ strukturalne nezaposlenosti (ova vrsta ne pripada tradicionalnoj podjeli nezaposlenosti) koja podrazumijeva nezaposlenost koja nastaje kao rezultat toga što neko gospodarstvo (države, regije) nije dovoljno da bi se zaposlila sva raspoloživa radna snaga. Iako se može pojaviti i u razvijenim zemljama, ovakva nezaposlenosti tipična je za zemlje u razvoju.

Proširenjem tipa strukturalne nezaposlenosti može se smatrati i fenomen tehničke nezaposlenosti. Ona se odnosi na nezaposlenost kojoj je uzrok napredak tehnologije, koja vodi do veće produktivnosti, a pritom reducira količinu potrebe za radom. Ovakvi uvjeti vode do potrebe za strukturalnim promjenama u potražnji za radom, a ukoliko se prilagodba ne dogodi dovoljno brzo, dolazi do tehnički uzrokovano rasta nezaposlenosti.

Posljednja, treća vrsta, prema tradicionalnoj podjeli nezaposlenosti jest ciklička ili konjunkturalna nezaposlenosti koja nastaje kao posljedica izmjene poslovnih ciklusa u kojima dolazi do smanjene potražnje za robom, pa samim time i radnicima, dok njihova ponuda ostaje ista. Pretpostavlja se da nakon toga dolazi do ponovne ekspanzije gospodarstva koja rješava problem ove vrste nezaposlenosti.

Navedeni tipovi nezaposlenosti pripadaju otvorenoj (evidentiranoj) nezaposlenosti, a osim nje, prisutan je i fenomen prikrivene nezaposlenosti. S jedne strane, prikrivena

nezaposlenost odnosi se na već spomenute tako zvane „obeshrabljene“ radnike, to jest osobe koje ne traže posao jer smatraju da ga ne mogu pronaći. S druge strane, prikrivena nezaposlenost može se promatrati i kao fenomen kada se zaposlena radna snaga ne iskorištava dovoljno ili adekvatno – to jest, kada se dio stanovništva formalno smatra zaposlenima, ali njihovo zaposlenje ostvaruje nikakav ili nedovoljan ekonomski efekt (Jurić, 1980).

Ekonomska teorija razdvaja nezaposlenost na dobrovoljnu i nedobrovoljnu, pri čemu se dobrovoljno nezaposlenima smatraju oni koji su odbili ponuđeni posao. Smatra se da je nekoliko razloga zbog kojih dolazi do odbijanja poslova:

1. Velike naknade za nezaposlene, koje čine prihvaćanje posla manje atraktivnim
2. Visoki porezi
3. Osoba se nada da će naći posao koji više odgovara njezinim sposobnostima i/ili kvalifikacijama
4. Neki poslovi se smatraju ponižavajućima ili previše zamornima,

Međutim, Mrnjevac ističe da ova podjela nije striktna budući da se izrazi dobrovoljno i nedobrovoljno ne mogu upotrijebiti u svojim jednostavnim svakodnevnim značenjima. Na primjer, osoba može dobrovoljno napustiti trenutni posao jer se nada da će brzo naći drugi posao, ali zbog uvjeta na tržištu rada to ne uspije, ali unatoč dobrovoljnom napuštanju prethodnog posla, njena trenutna nezaposlenost nije dobrovoljna (Mrnjevac, 1997).

Osim osobne važnost za pojedinca i njegovu egzistenciju, zaposlenost i stopa zaposlenosti važne su za društvo u cjelini. Nezaposleno stanovništvo, ne samo da državi predstavlja trošak ukoliko mu se isplaćuje neka vrsta socijalne naknade, već je i propušteni dobitak jer ga se ne može oporezivati. Za samog pojedinca, osim što mu pruža ekonomsku sigurnost, rad donosi i socijalnu interakciju, strukturira mu vrijeme te je jedan od izvora identiteta i samopoštovanja. Zbog tih aspekata, nezaposlenost može biti uzrok brojnih posljedica na psihološko zdravlje. Anksioznost, depresija, nezadovoljstvo životom, napetost, sniženo samopoštovanje, osjećaj beznađa neka su od emocionalnih stanja koja su češće utvrđena kod nezaposlenih nego zaposlenih osoba (Matko, 2002). Budući da nezaposlenost ne pogađa samo nezaposlenog pojedinca, već i njegovu obitelj, kao i širu društvenu zajednicu, neke od potencijalnih socijalnih posljedica nezaposlenosti su promjene u radnoj etici i vrijednostima rada, kriminalno ponašanje i delikvencija te pojava „podklase“ socijalno isključenih (Nekić, 2002).

2. Ciljevi i svrha rada

Svrha ovog rada je teorijski opisati i empirijski provjeriti socio-demografske karakteristike koje doprinose većoj šansi za bivanje nezaposlenom osobom u Republici Hrvatskoj te time doprinijeti znanstvenim i javno-političkim saznanjima na ovu temu.

Cilj je izgradnja općeg statističkog modela šansi za nezaposlenost.

3. Teorijski koncept rada


3.1. Nezaposlenost u Hrvatskoj

Nezaposlenost se evidentira na dva načina – preko prijave na Zavod za zapošljavanje te preko periodično provedene Ankete radne snage. Podaci dobiveni na ova dva načina ne poklapaju se u potpunosti. Razlog tome je što nije nužno da se sve nezaposlene osobe prijavljuju u Zavod za zapošljavanje, stoga dio nezaposlenih nije obuhvaćen tom evidencijom. S druge strane, sve osobe koje su evidentirane na Zavodu za zapošljavanje kao nezaposlene, ne zadovoljavaju nužno sve kriterije za evidentiranje nezaposlenih u Anketi radne snage, s obzirom na definiciju nezaposlenosti kojom se vodi Anketa radne snage (nezaposlena osoba treba zadovoljiti tri uvjeta: 1) nema posao, 2) raspoloživa je krenuti obavljati posao u referentnom periodu i 3) traži posao).

Unatoč tome što se vodi standardnom definicijom nezaposlenosti te joj je metodologija usklađena s pravilima i uputama Međunarodne organizacije rada te Europskog ureda za statistiku (Eurostat), Anketa radne snage također ima svoje mane – s obzirom da se provodi na uzorku, njeni rezultati nalaze se unutar greške mjerenja, a s obzirom na skupoću provedbe, od 1998. godine Anketa se provodi kontinuirano na godišnjoj razini, što nikako nije dovoljno često za kvalitetnu evidenciju, dok se od 2007. primjenjuje se kao panel istraživanje u kojem svaki ispitanik odgovara četiri puta u periodu od godinu i pol. Osim toga, potrebno je uzeti u obzir to da odgovori ispitanika nisu nužno potpuno iskreni i točni.

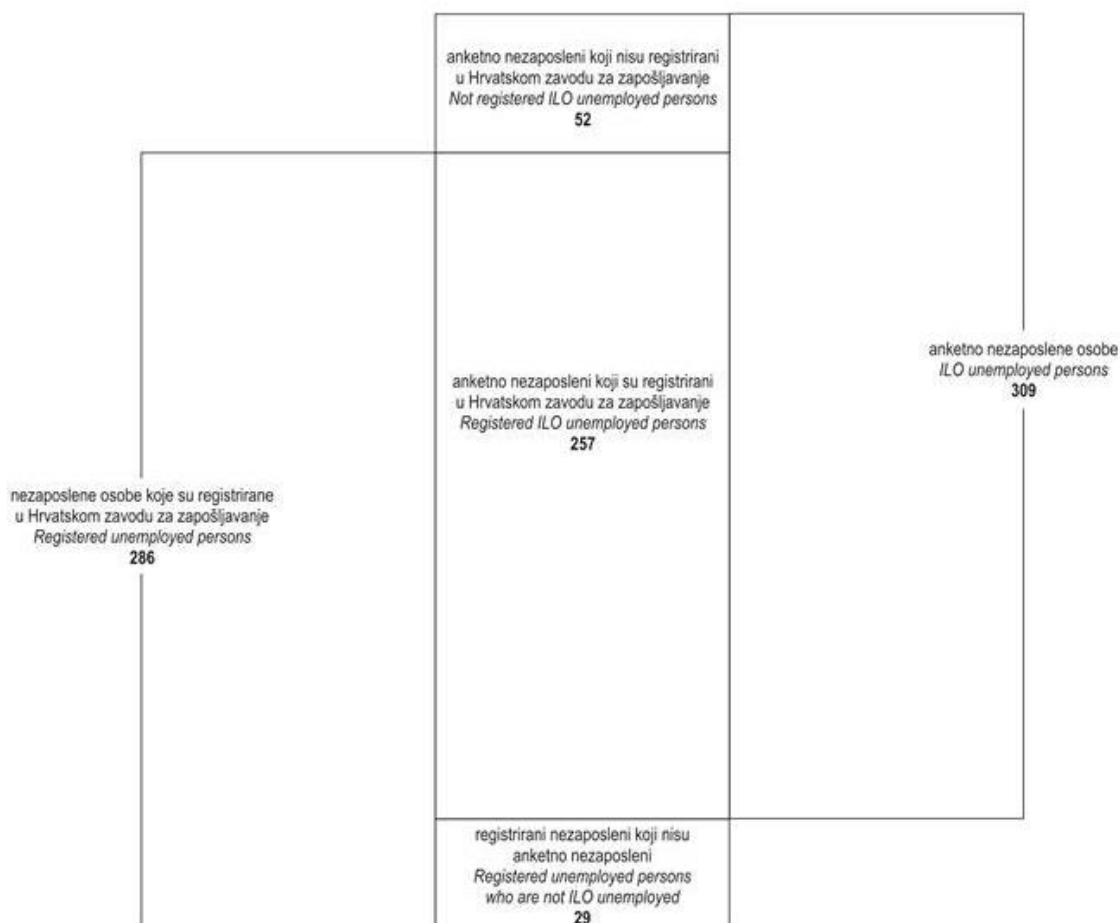
Anketa radne snage u Hrvatskoj je prvi put provedena 1995. godine. Mrnjevac pokazuje (slika 2) kako je samo 38 posto registriranih nezaposlenih bilo nezaposleno i prema Anketi radne snage. Čak 36 posto registriranih nezaposlenih radilo je tijekom referentnog tjedna što ih prema kriterijima ankete radne snage svrstava u kategoriju zaposlenih. Ostali registrirani nezaposleni pripadali su u kategoriju 'izvan radne snage'. Čak 26 posto stvarno nezaposlenih nije bilo prijavljeno Zavodu. Iz toga proizlazi da je preklapanje tih dviju

statističkih koncepcija 74 posto od nezaposlenih po međunarodnim standardima i samo 38 posto od registriranih ispitanika (prema Mrnjavac, 1996).



Slika 2. Poklapanje evidencije nezaposlenih osoba prema podacima iz Ankete o radnoj snazi te administrativnih podataka za 1995. godinu

U priopćenju Hrvatskog zavoda za statistiku o Aktivnom stanovništvu u Republici Hrvatskoj 2015. (prosjeak godine) stoji da „Usporedba podataka o nezaposlenima dobivenih Anketom, prema podacima Hrvatskog zavoda za zapošljavanje (HZZ-a) i drugih statističkih praćenja temeljenih na administrativnim izvorima pokazuje da je prosječna stopa nezaposlenosti u 2015. prema podacima administrativnih evidencija veća (17,4%) od stope anketne nezaposlenosti (16,3%). U tom razdoblju prosječan broj nezaposlenih prema Anketi veći je za 23 000 od podataka Hrvatskog zavoda za zapošljavanje što upućuje na smanjenje broja nezaposlenih osoba koje se prijavljuju na HZZ. Budući da su se anketirane osobe izjašnjavale o prijavljenosti službi za zapošljavanje, usporedba podataka pokazuje da je od ukupno 309 000 nezaposlenih prema Anketi, 257 000 ili 83,3% prijavljeno službi za zapošljavanje. Ostalih 16,7% anketno nezaposlenih nije bilo zainteresirano za prijavu službi za zapošljavanje. Istodobno od ukupno 286 000 registriranih u Hrvatskom zavodu za zapošljavanje, 29 000 ili 9,9% ne zadovoljava međunarodne kriterije nezaposlenosti.“ Isto je prikazano na slici 3.



Slika 3. Usporedba broja nezaposlenih osoba prema podacima iz Ankete o radnoj snazi te administrativnih podataka za 2015. godinu (u tisućama)¹

S obzirom da je u 1995. poklapanje između ova dva izvora iznosilo 74% (nezaposlenih prema evidenciji Zavoda ujedno su i nezaposleni prema Anketi radne snage) i 38% (nezaposlenih prema Anketi radne snage, ujedno upisani i u registar službe za zapošljavanje), a u 2015. ono iznosi 83% (nezaposlenih prema Anketi prijavljeno službi za zapošljavanje) i 90% (prijavljeno službi za zapošljavanje ujedno upisani u Anketu radne snage kao nezaposleni), možemo zaključiti da se poklapanje evidencije Zavoda za zapošljavanje i Ankete radne snage tokom vremena provođenja međusobno približilo te razlika više nije toliko velika. Jedan od razloga tome može biti promjena zakonodavnog okvira, prema kojem za stjecanje određenih socijalnih prava (npr. osnovna zdravstvena zaštita) nije nužno biti prijavljen u evidenciju Zavoda za zapošljavanje.

U nastavku, osvrnut ćemo se na kretanje stope nezaposlenosti u Hrvatskoj prema podacima Ankete radne snage.

¹ Izvor: Državni zavod za statistiku, Priopćenje 9.2.8. Aktivno stanovništvo u Republici Hrvatskoj u 2015. – prosjek godine

Tablica 1. Broj radno aktivnog stanovništva, broj nezaposlenih te stopa nezaposlenosti u razdoblju od 2008. do 2016. godine prema podacima Ankete radne snage² i evidenciji pri Zavodu za zapošljavanje³

Godina	Broj radno aktivnih stanovnika (u tisućama)	Broj nezaposlenih (u tisućama)	Stopa nezaposlenosti	Stopa registrirane nezaposlenosti
2008.	1 785	149	8,4%	14,3%
2009.	1 765	160	9,1%	15,1%
2010.	1 747	206	11,8%	18,2%
2011.	1 724	232	13,5%	19,1%
2012.	1 718	272	15,8%	19,7%
2013.	1 842	318	17,3%	21,5%
2014.	1 893	327	17,3%	22,2%
2015.	1 891	306	16,2%	19,3%
2016.	1 830	240	13,1%	16,9%

Kao što je vidljivo u tablici, prosječna nezaposlenost je 2008. godine bila na 8,4%, nakon čega, pod utjecajem ekonomske krize, kontinuirano raste do 2013. godine, kad poprima rekordnih 17,7%. Sljedeće, 2014. godine, minimalno je niža te iznosi 17,6%, te iduće dvije godine također pada. U 2016. godini, stopa nezaposlenosti iznosila je 13,2%, dakle, i dalje dosta više nego u razdoblju prije rasta.

Apsolutni broj nezaposlenih osoba u 4 se godine udvostručio – s 149 tisuća 2008. godine na gotovo 300 tisuća 2012., te na razini višoj od 300 tisuća ostaje sljedeće 3 godine. Najviši iznos postignut je 2014. godine, kada je iznosio 327 tisuća.


Trend kretanja ukupnog udjela nezaposlenosti nije nužno u skladu s kretanjem udjela nezaposlenosti u različitim društvenim skupinama. Matković iznosi kako „općenito poboljšanje stanja lako može prikrivati trendove opstanka ili rasta nezaposlenosti, nepovoljnih ishoda u svijetu rada, pa i socijalne isključenosti u pojedinim segmentima populacije“ (Matković, 2008:479). Na tragu toga, sada ćemo prikazati kretanje udjela nezaposlenosti s obzirom na sociodemografske karakteristike.

² Tablica je vlastite izrade, kreirana na temelju podataka Ankete radne snage dostupnih u okviru publikacije Državnog zavoda za statistiku Republike Hrvatske Statistika u nizu (dostupno na URL: <https://www.dzs.hr/Hrv/publication/StatisticsInLine.htm>) te Mjesečnog statističkog izvješća. Podaci Ankete radne snage prikupljeni su kvartalno, a za potrebe ovog rada prikazane su aritmetičke sredine kvartalnih podataka na godišnjoj razini.

³Podaci o registriranoj zaposlenosti preuzeti iz publikacije Statistika u nizu: Zaposlenost i plaće – pregled po županijama

3.2. Nezaposlenost s obzirom na dob

Kao što je već napomenuto, nezaposlenost ne pogađa sve društvene skupine jednako, a najveće razlike pronalaze se s obzirom na dob.



Slika 4. Stopa nezaposlenosti prema dobnim skupinama u razdoblju od 2008. do 2016. godine prema podacima Ankete radne snage

Iz grafičkog prikaza vidljivo je da je u svakoj od promatranih godina nezaposlenost najviša unutar najmlađe dobne skupine, to jest, među osobama od 15 do 24 godine. Ona je 2008. godine iznosila 22,0%, kontinuirano raste do 2013. godine kad je čak polovina mladih bila nezaposlena, te zatim postepeno pada - 2016. godine iznosila je 31,3%. Katić ističe kako je visoka stopa nezaposlenosti mladih često indikator rigidnog sustava koji se očituje u teškom otpuštanju radnika, pa posljedično i težem zapošljavanju novih radnika i otvaranju novih radnih mjesta te zbog toga sve više mladih prolongira svoje školovanje kako bi što kasnije izašli na tržište rada (Katić, 2006).

Isti trend kretanja stope nezaposlenosti vidljiv je i u preostale dvije dobne skupine, izuzevši pad između 2008. i 2009. godine u dobnoj skupini od 50 do 64 godine, iako su udjeli nezaposlenosti u njima mnogo manji. Tako je 2008. godine među osobama u dobi od 25 do 49 godina bilo 7,4% nezaposlenih, a među osobama u dobi od 50 do 64 godine njih 6,3%. Stopa nezaposlenih u dobi od 25 do 49 godina svoju najvišu vrijednost također postiže 2013. godine te tada iznosi 16,2%, što je u odnosu na 2008. rast veći od 100%. Najstarija dobna skupina najvišu stopu nezaposlenosti postiže 2014. godine te ona tada iznosi 12,0%.

Iako bi trebali biti osnovni ljudski resurs, problem nezaposlenosti mladih karakterističan je za cijelu Europsku uniju, što predstavlja ozbiljni ekonomski, socijalni i politički problem. Ekonomske posljedice nezaposlenosti mladih očituju se u smanjenju prihoda države, dok se socijalne posljedice odnose na čitav niz negativnih efekata koje nezaposlenost donosi za mladog pojedinca (depresivnost, strahovi, beznade...), a koji mogu rezultirati rastom kriminala i zloupotrebe opijata s jedne strane te odgađanjem osnivanja obitelji i pada nataliteta s druge (Bilić, Jukić, 2014). Sam stres i njegov dugoročni utjecaj na zdravlje također nisu zanemariva posljedica. Bilić i Jukić objašnjavaju kako nezaposlenost mladih može dovesti do političkih nemira jer „velik broj nezaposlenih mladih znači smanjenje poreznih obveznika što izravno utječe na smanjenje državnih prihoda. Povećanje nezaposlenosti mladih uzrokuje veća izdvajanja za socijalne naknade. Država se neminovno suočava s proračunskim deficitom koji mora podmiriti najčešće povećanjem poreza. Povećanje poreza utječe na daljnje smanjivanje kupovne moći kao i na veći pritisak na poslodavce. Takvo nesigurno okruženje povećava mogućnost za nemire i prosvjede koji mogu utjecati na političku sigurnost zemlje“ (Bilić, Jukić, 2014:495).


Analizirajući razlike u nezaposlenosti i kvaliteti zaposlenosti po dobnim skupinama, Matković ističe nekoliko problema – kao prvo, sukladno prethodno spomenutom, iako nezaposlenost mladih prati trendove ukupne nezaposlenosti, ona je 2,5-2,8 puta veća od nje zbog čega su mladi u posebno ranjivom položaju. Drugi problem koji ističe također je vezan uz mlade, to jest, radno sposobno stanovništvo mlađe od 25 godina, za koje kaže da je većinski srednje strukovno obrazovano te vrlo često radi nekvalitetne poslove. Iako velik dio starijih radnika jesu visokoobrazovani te su zaposleni kao stručnjaci u javnom sektoru ili su vlasnici obrta, treći problem koji Matković ističe jesu stariji nekvalificirani radnici koji rade nekvalitetne, najčešće poljoprivredne, poslove (Matković, 2008).

Kada je riječ o posljedicama nezaposlenosti mladih, nužno je spomenuti i to da ona za posljedicu ima iseljavanje. Prema podacima Državnog zavoda za statistiku, u 2016. godini Hrvatsku je napustilo ukupno 36 436 osoba, dok je 2008. taj broj iznosio gotovo pet puta manje - 7 488 te se smatra se da se najviše iseljavaju upravo pripadnici mlađe dobi. Kada se govori o problemu iseljavanja mladih, najčešće se fokus stavlja na fenomen takozvanog „odljeva mozгова“, koji predstavlja iseljavanje visokoobrazovanih stručnjaka iz zemlje u kojoj su rođeni i u kojoj su se školovali. To predstavlja velik gubitak na dvije razine – kao prvo, svi resursi koji su uloženi u obrazovanje osobe (iako uz određene uvjete za visoko

obrazovanje, javno obrazovanje u Hrvatskoj na svim je razinama besplatno)⁴ uzalud su potraćeni, a kao drugo, s vremenom dolazi do nedostatka visokoobrazovanog kadra zbog čega se kvaliteta usluga smanjuje. Nedovoljno liječnika, različitih vrsta inženjera i znanstvenika različitih vrsta problem je s kojim se Hrvatska već sada susreće, a s rastućim trendom iseljavanja, on će postajati još i veći, što ponovno predstavlja prepreke za ekonomski rast.

3.3. Nezaposlenost s obzirom na spol

Razlike između muškaraca i žena u svijetu rada prisutne su na svim razinama, pa tako i što se tiče nezaposlenosti. Stope nezaposlenosti muškaraca i žena ne razlikuju se toliko kao one unutar dobnih skupina, ali u većini promatranih godina, prosječna stopa nezaposlenosti muškaraca, nešto je niža nego ona kod žena. Kretanje prosječnih stopa nezaposlenosti po spolu prikazano je na slici 5.



Slika 5. Stopa nezaposlenosti prema dobnim skupinama u razdoblju od 2008. do 2016. godine prema podacima Ankete radne snage (prosjeak godine)

2008. godine stopa nezaposlenosti muškaraca iznosila je 7%, a žena 10% te je to ujedno točka mjerenja u kojoj se ove dvije grupe najviše razlikuju. Vidljiv je trend rasta

⁴ Potrebno je uzeti u obzir da, osim besplatnog obrazovanja, ovdje ulaze i sve druge vrste financijskog pomaganja kao što su stipendije, naknade, povoljno kreditiranje te različite vrste popusta i olakšica, ali i nefinancijske podrške u vidu savjetovališta, radionica i drugih sadržaja namijenjenim studentima.

nezaposlenost do 2013. kod muškaraca te do 2014. kod žena, pri čemu se taj rast nije događao istim intenzitetom. Do 2011. stopa nezaposlenosti muškaraca raste nešto brže nego stopa nezaposlenosti žena te je tako u 2011., 2012. i 2013. godini prosječna stopa nezaposlenosti muškaraca nešto više nego ona kod žena. Zatim u 2014. godini, nezaposlenost žena raste, a muškaraca pada, te je nezaposlenost žena ponovno viša nego muškaraca.


Promatrane tri godine u kojima je nezaposlenost žena nešto niža nego nezaposlenost muškaraca su izuzetak, budući da se svi dosadašnji radovi koji su se bavili analizom zaposlenosti po spolu susreću s nepovoljnijim položajem žena u svijetu rada. Uspoređujući agregirane podatke Ankete radne snage od 2004. do 2006. godine te od 1996. do 1998. godine, Matković je „potvrdio postojanje razlika između dobnih skupina te populacije muškaraca i žena u mnogim dimenzijama participacije na tržištu rada, položaju u podjeli rada, oblicima zaposlenosti i kvaliteti zaposlenosti“ (Matković, 2008:498). Analiza pokazuje kako je tijekom cijelog promatranog razdoblja stopa nezaposlenosti žena nešto viša od stope nezaposlenosti muškaraca, a u vrijeme kada dolazi do ekonomskog oporavka, nezaposlenost muškaraca se ranije i brže kreće smanjivati. Osim toga, prema podacima iz razdoblja 1996.-1998., udio dugotrajno nezaposlenih u ukupnom broju nezaposlenih za muškarce i žene bio je jednak (55,8%), dok je prema podacima 2004.-2006. kod žena porastao na 61,6%, a kod muškaraca primjećujemo tek blagi porast na 57,2% dugotrajno nezaposlenih u ukupnom broju nezaposlenih. Primjetna je i razlika u sektoru, vrsti i kvaliteti zaposlenja, na način da su žene rjeđe poslodavci i samozaposlene te češće rade nesigurne i nekvalitetne poslove⁵.

Osim što to pokazuju statistike, žene, kada traže posao, često se i same osjećaju „zapostavljeno“ zbog toga što su žene (Galić, Nikodem, 2009). Kerovec ističe kako važnost jednakosti žena na tržištu rada nije samo pitanje socijalne pravednosti, već da je to i ekonomska nužnost, kako bi društvo maksimalno iskoristilo društvene resurse kojima raspolaže. Kao i Matković, Kerovec također skreće pažnju da sama stopa nezaposlenosti nije jedini indikator koji može ukazati na neravnopravan položaj određene skupine, u ovom slučaju žena, te treba obratiti pažnju i na samu kvalitetu zaposlenosti. Na primjer, u nekim zemljama Europske unije vidljiv je trend češćeg zapošljavanja žena na nepuno radno vrijeme (engl. *part-time*) poslove koji su obično lošije plaćeni i generalno slabije regulirani (Kerovec, 2003). Ipak, zbog opsega i specifičnog usmjerenja ovog rada, pitanje kvalitete zaposlenja neće se analizirati.

⁵ „Nekvalitetna zaposlenost uključuje svaki neželjeni posao na određeno ili u nepunom radnom vremenu, neformalnu samozaposlenost te poslove u kojima se ne ostvaruju pojedina prava.“ (Matković, 2008T:487)

3.4. Nezaposlenost s obzirom na obrazovanje i zanimanje

S obzirom na to da u najvećoj mjeri određuju vrstu posla kojom se osoba može baviti, obrazovanje i zanimanje najbitnije su karakteristike koje određuju šanse za uspjeh na tržištu rada. U Hrvatskoj je većina stanovništva u dobi od 15 do 64 godine srednjeg obrazovanja, nešto manje od trećine je niskoobrazovano, a udio stanovništva višeg obrazovanja je u porastu, trenutno oko 16%. Na slici 6 prikazani su omjeri obrazovnih kategorija unutar ukupnog broja nezaposlenih osoba.



Slika 6. Udio osoba nižeg, srednjeg i višeg obrazovanja⁶ u ukupnom broju nezaposlenih u razdoblju od 2008. do 2016. godine prema podacima Ankete radne snage (prosjeak godine)

S obzirom da čine većinu stanovništva, očekivano, osobe srednjeg obrazovanja čine većinu nezaposlenog stanovništva – oko 70%. Udio niskoobrazovanih nezaposlenih osoba varira te mu se ne može jasno izdvojiti trend rasta ili pada, dok se za udio visokoobrazovanih nezaposlenih osoba može, uz određene izuzetke, zaključiti da postepeno pada. Zbog još uvijek relativno visokog udjela niskoobrazovanih osoba u ukupnom stanovništvu, potrebno je pojasniti da upravo niskoobrazovane osobe čine najveći dio neaktivnog stanovništva, stoga je njihov udio u nezaposlenima relativno nizak.

Budući da se promatrano razdoblje proteže od 2008. do 2016, iz ovog grafičkog prikaza to nije vidljivo, ali Obadić i Majić ističu kako je nagli rast visokoobrazovanih osoba

⁶Niže obrazovanje obuhvaća nezavršenu ili završenu osnovnu školu, srednje završenu srednju strukovnu školu ili gimnaziju, dok kategorija višeg obrazovanja obuhvaća završenu višu školu, magisterij ili doktorat

od 2006. godine također doveo do rasta broja nezaposlenih osoba tercijarnog obrazovanja. Autorice u prvom redu ističu problem neusklađenosti ponude i potražnje zanimanja, pri čemu je poseban naglasak stavljen na velik broj diplomaca društvenih znanosti.

Izvješća o Anketi radne snage ne izvještavaju o strukturi zanimanja nezaposlenih osoba ali zato Hrvatski zavod za zapošljavanje vodi evidenciju o tome kojeg su zanimanja osobe koje se prijavljuju kao nezaposlene⁷. U travnju 2016. godine, najviši udio nezaposlenih osoba dolazio je iz ovih grupa zanimanja: jednostavna zanimanja u rudarstvu, građevinarstvu, proizvodnji i prometu, trgovačka zanimanja, čistači, perači, kućne pomoćnice i srodna zanimanja, uslužna zanimanja te tehničari tehničko-tehnoloških zanimanja.

3.5.Regionalne razlike u nezaposlenosti

S obzirom na to da nisu svi dijelovi Hrvatske jednako ekonomski razvijeni, šanse za uspješan osobni ishod na tržištu rada određen je i mjestom stanovanja. Tablica 2 prikazuje udio nezaposlenih prema županijama. Ovo su podaci dobiveni iz administrativnih izvora, dakle, radi se o stopi registrirane nezaposlenosti.

Tablica 2. Udio nezaposlenih osoba po županijama (Administrativni izvori)

	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.
Republika Hrvatska	14,3	15,1	18,2	19,1	19,7	21,5	22,2	19,3	16,9
Zagrebačka	10,6	11,6	16,3	18,0	18,6	21,5	21,9	18,2	15,1
Krapinsko-zagorska	9,6	11,7	16,4	18,2	19,8	21,3	21,1	17,7	14,6
Sisačko-moslavačka	24,9	27,4	30,8	30,9	33,2	34,8	36,2	34,4	32,3
Karlovačka	21,8	23,0	26,0	25,0	25,7	26,2	25,6	24,0	21,2
Varaždinska	9,8	11,2	14,1	15,0	15,4	16,9	15,8	12,4	9,5
Koprivničko-križevačka	14,0	14,3	18,6	18,7	20,4	23,9	24,4	19,7	16,7
Bjelovarsko-bilogorska	23,1	25,0	29,3	28,8	29,0	30,2	32,0	31,0	27,5
Primorsko-goranska	10,8	11,6	14,8	15,7	15,6	17,0	17,9	14,9	13,0
Ličko-senjska	18,8	18,9	21,5	22,3	20,9	23,0	24,6	23,3	22,3
Virovitičko-podravka	25,8	27,3	30,4	32,5	35,4	36,2	38,1	35,8	32,7
Požeško-slavonska	19,4	21,5	24,4	26,2	27,6	30,5	31,4	26,2	22,8
Brodsko-posavska	24,7	26,2	31,9	33,8	34,7	37,0	38,0	30,8	27,1
Zadarska	17,7	18,7	21,1	21,0	21,1	22,5	22,5	17,7	16,0
Osječko-baranjska	22,0	23,3	28,2	28,5	29,3	32,1	34,3	31,9	28,8
Šibensko-kninska	19,6	20,6	23,3	23,3	24,0	24,8	25,5	23,3	22,5
Vukovarsko-srijemska	27,5	28,7	31,8	32,2	32,9	35,8	38,0	33,6	29,7
Splitsko-dalmatinska	19,1	19,4	22,7	24,0	25,8	27,9	28,6	26,1	24,1
Istarska	6,7	8,4	10,7	11,5	10,9	12,6	12,9	9,9	8,4

⁷Evidencija nezaposlenih po zanimanju za promatrano razdoblje dostupna na: <http://trzisterada.hzz.hr/Unemployment/Occupation?timeid=201604&rend=3>

Dubrovačko-neretvanska	15,3	15,5	17,9	18,8	19,0	20,5	21,5	20,5	18,3
Međimurska	11,6	12,7	16,6	16,8	18,0	18,7	18,7	14,7	12,1
Grad Zagreb	6,2	6,3	8,4	9,4	9,5	10,8	11,2	9,6	8,2

Registrirana nezaposlenost, osim u gradu Zagrebu, najniža je u Istarskoj županiji, a potom slijede Međimurska i Varaždinska županija. Kao županije s najvećim udjelom nezaposlenih ističu se Sisačko-moslavačka, Virovitičko-podravska, Brodsko-posavska, Osječko-baranjska i Vukovarsko-srijemska županija.

Botić je analizirala vezu između kretanja razine nezaposlenosti na nacionalnoj razini te kretanja nezaposlenosti na razini regija⁸, te zaključuje da se s obzirom na kretanje razine nezaposlenosti, Hrvatska može podijeliti na tri grupe: „1. Regije u kojima je povezanost između kretanja na tržištu rada na nacionalnoj razini i kretanja na regionalnoj razini značajno izražena - ovdje se radi o Središnjoj Hrvatskoj; 2. Regije u kojima je povezanost između kretanja na nacionalnoj i regionalnoj razini izražena, ali postoji i regionalni utjecaj - Zapadna, Južna i Sjeverna Hrvatska; 3. Regije u kojima su snažnije izražene regionalne specifičnosti - Istočna Hrvatska“ (Botić, 2003:39). To se djelomično može vidjeti i iz trendova kretanja nezaposlenosti po županijama.

3.6. Nezaposlenost s obzirom na ostale karakteristike

Šansa za zapošljavanje ovisi i o cijelom setu osobnih karakteristika kao što su motivacija za zapošljavanjem, kvaliteta prethodnih radnih iskustava, načini traženja zaposlenja, razina samopouzdanja i mnogi drugi. Ipak, to su kompleksni konstrukti te njihov utjecaj u okviru ovog rada nije moguće testirati.

S druge strane, obiteljsku situaciju pojedinca relativno je lako ispitati, a možemo pretpostaviti da osobe u različitom bračnom ili roditeljskom statusu mogu imati različite preferencije spram svoje zaposlenosti ili da će tržište rada biti različito naklonjeno osobama različitih obiteljskih karakteristika. Na primjer, osobe koje su u braku mogu se oslanjati na primanja svojih supružnika, dok su neoženjeni i neudate ili rastavljeni i rastavljene ovisniji o

⁸„Hrvatska podijeljena u sljedećih pet regija: Sjeverna Hrvatska (oznaka SJ) koja uključuje sljedeće županije: Krapinsko-zagorska, Varaždinska, Koprivničko-križevačka i Međimurska; Središnja hrvatska (oznaka SR): Zagrebačka, Sisačko-moslavačka, Karlovačka, Bjelovarsko-bilogorska, Grad Zagreb; Istočna Hrvatska (oznaka IS): Virovitičko-podravska, Požeško-slavonska, Brodsko-posavska, Osječko-baranjska i Vukovarsko-srijemska županija; Zapadna Hrvatska (oznaka ZA): Primorsko-goranska, Ličko-senjska i Istarska županija te Južna Hrvatska (oznaka JU): Zadarska, Šibensko-kninska, Splitsko-dalmatinska i Dubrovačko-neretvanska županija“ (Botić, 2003:33)

vlastitim prihodima. Također, osobe bez djece vjerojatno su fleksibilnije pri traženju zaposlenja, na primjer, lakše im se preseliti u drugi grad zbog potrage za poslom.

Potrebno je uzeti u obzir da su bračni i roditeljski status pod utjecajem drugih sociodemografskih karakteristika, prvenstveno dobi i spola, te se njihova veza s radnim statusom treba promatrati slojevito – tako bi kod žena roditeljstvo moglo voditi češćem ostajanju u statusu nezaposlene ili neaktivne osobe, dok kod muškaraca može biti poticaj za veću motivaciju pri pronalasku zaposlenja. Ova pretpostavka ima svoje utemeljenje u društvenom kontekstu koji još uvijek preferira ideju žene kao majke koja brine za djecu i kućanstvo, a muškarca kao onog tko privređuje za cijelu obitelj. Ipak, s obzirom na opseg ovog rada, zadržat ćemo se na testiranju utjecaja bračnog statusa i roditeljstva na opći model nezaposlenosti, bez pravljenja razlika između sub-uzoraka.

4. Hipoteze

Osnovna hipoteza ovog rada je da se pripadanje kategoriji nezaposlenih osoba može objasniti prediktorskim sklopom koji se sastoji od sociodemografskih varijabli – spol, dob, regija, tip mjesta stanovanja (urbano ili ruralno područje), veličina mjesta stanovanja, obrazovanje, zanimanje, bračni status i suživot s vlastitom malodobnom djecom.

Iz osnovne hipoteze izvedeno je nekoliko hipoteza koje glase:

1. Niže obrazovanje je prediktor koji višestruko povećava šansu da osoba bude nezaposlena.
2. Kategorije zanimanja kvalificirani radnici te niskokvalificirani i nekvalificirani radnici su prediktori koji višestruko povećavaju šansu da osoba bude nezaposlena.
3. Ženski spol i ruralni tip stanovanja umjereno povećavaju šansu da osoba bude nezaposlena.
4. Život u regiji Slavonija je prediktor koji, u usporedbi s ostalim regijama, najviše povećava šansu da osoba bude nezaposlena.
5. Utjecaj bračnog statusa i suživota s vlastitom malodobnom djecom na šansu da osoba bude nezaposlena je relativno nizak.

5. Metodologija

5.1.Prikupljanje podataka

Za potrebe ovog rada, korišteni su podaci Omnibusa agencije Ipsos za razdoblje od 2008. do 2016. godine. Omnibus je indicirano istraživanje koje se na mjesečnoj razini provodi na nacionalno reprezentativnom uzorku stanovništva Republike Hrvatske starijeg od 15 godina.

Podatke prikupljaju profesionalni anketari agencije Ipsos prema uputama za slučajno uzorkovanje metodom nasumičnog hodanja (engl. *randomwalk*) i odabir ispitanika unutar kućanstva metodom posljednjeg rođendana) te u kućanstvu ispitanika provode anketiranje tehnikom licem u lice (engl. *face to face*) uz pomoć računala ili tableta (eng. *Computer Assisted Personal Interviewing, CAPI*). Anketari su obavezni predstaviti sebe i agenciju za koju rade, pokazati punomoć za provođenje istraživanja, objasniti ispitaniku temu istraživanja te okvirno trajanje ankete kako bi ispitanici mogli unaprijed odlučiti žele li to vrijeme izdvojiti za popunjavanje upitnika. Također, anketari ispitanicima daju dopis na kojem je zajamčena anonimnost ispitanika i povjerljivost podataka te je naveden kontakt broj agencije na koji se mogu javiti u slučaju bilo kakvih pitanja ili primjedbi. Nakon toga, ispitanici su zamoljeni za sudjelovanje za koje daju svoj usmeni pristanak. Ispitanici imaju pravo u bilo kojem trenutku odustati od sudjelovanja u anketi, ali im to pravo nije unaprijed spomenuto kako ih ne bi potaklo na odustajanje.

5.2.Uzorak

Za potrebe analize podataka, podaci su agregirani na godišnjoj razini te svedeni u tri točke mjerenja – prva, od 2008. do 2010.; druga, od 2011 do 2013. te treća, od 2014. do 2016. Kako bismo dobili uvid u to koji je uopće udio pojedinih kategorija radnog statusa, najprije ćemo se osvrnuti na ukupni uzorak u te tri točke mjerenja. Zatim ćemo opisati uzorak radno aktivnog stanovništva, to jest, uzorak koji će biti korišten u daljnjoj analizi.

5.2.1. Ukupni uzorak

Kao što je već spomenuto, u svrhu postizanja reprezentativnosti uzorka, prije početka obrade i analize, podaci su ponderirani prema najvažnijim sociodemografskim karakteristikama: spolu, dobi, obrazovanju te zastupljenosti ispitanika u ruralnim i urbanim

krajevima, stoga su karakteristike ovog uzorka ujedno i karakteristike populacije stanovništva Republike Hrvatske u dobi od 15 do 64 godine. Frekvencije kategorija sociodemografskih varijabli koje su relevantne za ovaj rad prikazane su u tablici 3.

Tablica 3. Deskriptivni prikaz ukupnog uzorka

		2008.-2010.		2011.-2013.		2014.-2016.	
		N	(%)	N	(%)	N	(%)
Spol	Muškarac	17103	47,5%	17141	47,5%	17171	47,6%
	Žena	18897	52,5%	18946	52,5%	18877	52,4%
Tip naselja	Selo	15397	42,8%	15461	42,8%	13944	38,7%
	Grad	20603	57,2%	20626	57,2%	22104	61,3%
Veličina naselja	Do 2000 stanovnika	15.397	42,8%	15461	42,8%	13944	38,7%
	2 001 - 10 000 stanovnika	5660	15,7%	5641	15,6%	5822	16,2%
	10 001 - 100 000 stanovnika	6384	17,7%	6579	18,2%	7163	19,9%
	100 001 i više stanovnika	8558	23,8%	8406	23,3%	9118	25,3%
Regija	Zagreb i okolica	8914	24,8%	8927	24,7%	9326	25,9%
	Sjeverna Hrvatska	6437	17,9%	6452	17,9%	6239	17,3%
	Slavonija	6331	17,6%	6345	17,6%	6020	16,7%
	Lika i Banovina	3151	8,8%	3160	8,8%	3009	8,3%
	Istra, Primorje i Gorski Kotar	4284	11,9%	4294	11,9%	4287	11,9%
	Dalmacija	6883	19,1%	6909	19,1%	7168	19,9%
Stupanj obrazovanja	Bez škole ili 1 do 3 razreda osnovne škole	1180	3,3%	935	2,6%	504	1,4%
	4 do 7 razreda osnovne škole	3642	10,1%	2995	8,3%	1822	5,1%
	Osnovna škola	9560	26,6%	10174	28,2%	8644	24,0%
	Jednogodišnja ili dvogodišnja stručna škola	439	1,2%	393	1,1%	345	1,0%
	Trogodišnja stručna škola za zanimanja	5348	14,9%	5843	16,2%	6349	17,6%
	Četverogodišnja stručna škola za zanimanja	10095	28,0%	10067	27,9%	11055	30,7%
	Gimnazija	1337	3,7%	1324	3,7%	1325	3,7%
	Viša škola, prvi stupanj fakulteta	1716	4,8%	1702	4,7%	2271	6,3%
	Fakultet, akademija, visoka škola	2435	6,8%	2413	6,7%	3304	9,2%
	Magisterij	100	0,3%	159	0,4%	311	0,9%
	Doktorat	42	0,1%	42	0,1%	67	0,2%
	Ne znam / Bez odgovora	105	0,3%	39	0,1%	52	0,1%
Trenutni radni status	Zaposleni kod nekoga	11965	33,2%	10569	29,3%	12806	35,5%
	Samostalno zaposleni - slobodne profesije	111	0,3%	102	0,3%	167	0,5%
	Samostalno zaposleni - poljoprivredno gospodarstvo, farma	374	1,0%	255	0,7%	211	0,6%

	Samostalno zaposleni - vlasnici poduzeća ili obrta	778	2,2%	777	2,2%	910	2,5%
	Nezaposleni	4392	12,2%	6031	16,7%	5724	15,9%
	Kućanice	2665	7,4%	2343	6,5%	1865	5,2%
	Učenici i studenti	4056	11,3%	3992	11,1%	3600	10,0%
	U mirovini	11447	31,8%	11878	32,9%	10618	29,5%
	Novaci u vojsci (ne aktivni)	9	0,0%	8	0,0%	3	0,0%
	Ne znam / Bez odgovora	203	0,6%	132	0,4%	143	0,4%
Zanimanje	Slobodna profesija	81	0,3%	79	0,3%	112	0,4%
	Stručnjaci i intelektualci	1830	6,3%	1812	6,1%	2414	7,9%
	Viši menadžment, viši rukovoditelji, direktori	757	2,6%	579	2,0%	680	2,2%
	Srednji menadžment	1228	4,2%	1169	3,9%	1301	4,3%
	Službenici	4128	14,2%	3834	12,9%	4514	14,8%
	Kvalificirani radnici, uključujući i bolničke sestre	12275	42,2%	13511	45,6%	13935	45,8%
	Nekvalificirani i niskokvalificirani radnici	4548	15,6%	5277	17,8%	4916	16,2%
	Poljoprivrednici i ribari	2072	7,1%	1895	6,4%	1277	4,2%
	Ne znam / Bez odgovora	2147	7,4%	1454	4,9%	1290	4,2%
Bračni status	Oženjen - udana	19733	54,8%	19720	54,6%	19603	54,4%
	Neoženjen - neudana	9471	26,3%	9509	26,4%	9865	27,4%
	Rastavljen - rastavljena	1461	4,1%	1672	4,6%	1910	5,3%
	Udovac - udovica	5272	14,6%	4944	13,7%	4328	12,0%
	Ne znam / Bez odgovora	63	0,2%	242	0,7%	342	0,9%
Suživot sa vlastitom malodobnom djecom	Osoba živi sa vlastitom maloljetnom djecom	8619	23,9%	8200	22,7%	8447	23,4%
	Osoba ne živi sa vlastitom maloljetnom djecom	27381	76,1%	27887	77,3%	27601	76,6%

Nešto više od polovice (52-53%) ukupnog uzorka čine žene. Zagreb i okolica (25-26%) najbrojnija su regija, slijedi je Dalmacija (19-20%), zatim Sjeverna Hrvatska i Slavonija (obje 17-18%). Stanovnici Istre, Primorja i Gorskog Kotara čine 12% populacije, pa tako i ovih uzoraka, a najmalobrojnija regija je Lika i Banovina (8-9%). Većina ispitanika (57-61% živi u urbanom području. Što se tiče stupnja obrazovanja, najveći udio ispitanika, kao svoj najviši oblik obrazovanja, navode završenu četverogodišnju stručnu školu za zanimanja. Još je uvijek prilično visok udio, gotovo trećina, onih koji su završili maksimalno osnovnu školu. U prvoj točki mjerenja, od 2008. do 2010. godine, neki oblik višeg obrazovanja prisutan je kod 12,0% ispitanika, u drugoj točki mjerenja jednako toliko, dok je u trećoj točki mjerenja vidljiv porast te udio ispitanika s nekim oblikom višeg obrazovanja iznosi 16,6%. Što se tiče zanimanja,

kvalificirani radnici, uključujući i bolničke sestre čine najbrojniju skupinu zanimanja kroz tri točke mjerenja. Sljedeće dvije grupe zanimanja po zastupljenosti su službenici te nekvalificirani i niskokvalificirani radnici. Nešto više od polovice ispitanika je u braku, a gotovo četvrtina ih živi s vlastitom malodobnom djecom.

Što se tiče radnog statusa, varijable od primarnog interesa u ovom radu, gotovo trećinu ispitanika čine umirovljenici, koji uz učenike i studente (otprilike 10%) te kućanice (njihov udio blago pada – u prvoj ih je 7,4%, 6,5% u drugoj te 5,2% u trećoj točki mjerenja) čine neaktivne osobe – njihov udio u prvoj (51,1%) i drugoj (50,9%) točki mjerenja iznose nešto malo više od polovice uzorka dok ih je u trećoj točki mjerenja 45,1%. Udio nezaposlenih ispitanika u prvoj točki mjerenja iznosi 12,2%, u drugoj 16,7%, a trećoj 15,9%. Primjećujemo porast od 2011. do 2013. godine te ponovni pad u točki mjerenja od 2014. do 2016. u skladu s kretanjem stope nezaposlenosti prikazanoj u tablici 1 u uvodnom djelu ovog rada. Što se tiče zaposlenih, najveće promjene vidljive su u kategoriji „zaposleni kod nekog“ – u prvoj točki mjerenja, njih je 33,2%, zatim im u drugoj točki udio pada na 29,3%, te u trećoj ponovno raste na 35,5%. Među samostalno zaposlenima, promjene nisu vidljive, njihov se udio u promatranom razdoblju kreće između 3 i 4%.

5.2.2. Analizirani uzorak

S obzirom da je ovaj rad usmjeren na usporedbu karakteristika nezaposlenih i zaposlenih osoba, neaktivno stanovništvo izostavljeno je iz analize. Slijedi pregled uzorka radno aktivnog stanovništva prema sociodemografskim karakteristikama koje će biti uključene u daljnju analizu.

Tablica 4.Deskriptivni prikaz analiziranog uzorka

		2008.-2010.		2011.-2013.		2014.-2016.	
		N	(%)	N	(%)	N	(%)
Spol	Muškarac	9836	55,8%	9757	55,0%	10407	52,5%
	Žena	7784	44,2%	7976	45,0%	9411	47,5%
Obrazovanje	Niže	3036	17,2%	3107	17,5%	2491	12,6%
	Srednje	11364	64,5%	11528	65,0%	12834	64,8%
	Više	3220	18,3%	3098	17,5%	4493	22,7%
Zanimanje	Slobodna profesija	64	0,4%	60	0,3%	90	0,5%
	Stručnjaci i intelektualci	1431	8,1%	1371	7,7%	1937	9,8%
	Viši menadžment, viši rukovoditelji, direktori	566	3,2%	395	2,2%	505	2,5%

	Srednji menedžment	973	5,5%	845	4,8%	990	5,0%
	Službenici	2825	16,0%	2513	14,2%	3208	16,2%
	Kvalificirani radnici, uključujući i bolničke sestre	9373	53,2%	9821	55,4%	10496	53,0%
	Nekvalificirani i niskokvalificirani radnici	1904	10,8%	2301	13,0%	2235	11,3%
	Poljoprivrednici i ribari	480	2,7%	426	2,4%	357	1,8%
Tip naselja	Selo	6806	38,6%	7013	39,5%	7059	35,6%
	Grad	10814	61,4%	10720	60,5%	12759	64,4%
Veličina naselja	Do 2000 stanovnika	6806	38,6%	7013	39,5%	7059	35,6%
	2 001 - 10 000 stanovnika	2883	16,4%	2906	16,4%	3280	16,6%
	10 001 - 100 000 stanovnika	3407	19,3%	3430	19,3%	4122	20,8%
	100 001 i više stanovnika	4524	25,7%	4384	24,7%	5357	27,0%
Regija	Zagreb i okolica	4571	25,9%	4556	25,7%	5402	27,3%
	Sjeverna Hrvatska	3118	17,7%	3100	17,5%	3336	16,8%
	Slavonija	2914	16,5%	2976	16,8%	3174	16,0%
	Lika i Banovina	1398	7,9%	1493	8,4%	1565	7,9%
	Istra, Primorje i Gorski Kotar	2306	13,1%	2323	13,1%	2471	12,5%
	Dalmacija	3313	18,8%	3286	18,5%	3871	19,5%
Bračni status	Oženjen - udana	11377	64,6%	11238	63,4%	12349	62,3%
	Neoženjen - neudana	4951	28,1%	5089	28,7%	5815	29,3%
	Rastavljen - rastavljena	921	5,2%	1046	5,9%	1251	6,3%
	Udovac - udovica	371	2,1%	361	2,0%	403	2,0%
Suživot sa vlastitom malodobnom djecom	Osoba živi s vlastitom maloljetnom djecom	7213	40,9%	6932	39,1%	7396	37,3%
	Osoba ne živi s vlastitom maloljetnom djecom	10408	59,1%	10801	60,9%	12423	62,7%

Među radno aktivnim ispitanicima, u sve tri točke mjerenja nešto je više muškaraca nego žena (za razliku od ukupnog uzorka, u kojem prevladavaju žene). Udio srednje obrazovanih je najviši u i ovom uzorku, te kroz sve tri točke mjerenja iznosi oko 65%, dok je vidljiv trend pada niže obrazovanih, a rasta više obrazovanih. Struktura zanimanja radno aktivnog uzorka slična je ukupnom uzorku, najveći udio također čine kvalificirani radnici, uključujući bolničke sestre, te se ne razlikuju između tri točke mjerenja. Bračni status u uzorku radno aktivnog stanovništva također se ne razlikuje između točaka mjerenja te je u njemu, u usporedbi s ukupnim uzorkom, nešto manje rastavljenih te udovaca - udovica, a više oženjenih – udanih. Također, udio osoba koje žive s vlastitom maloljetnom djecom veći je nego u ukupnom uzorku, ali blago pada kroz točke mjerenja.

5.3.Obrada podataka

Statistička obrada podataka provedena je uz računalni program IBM SPSS Statistics 23.0.

Rezultati na zavisnoj i nezavisnim varijablama prikazani su deskriptivnim pokazateljima frekvencijama i postocima te mjerama centralne tendencije i raspršenosti - aritmetičkom sredinom i standardnom devijacijom. U poglavlju „Mjerni instrumenti“ objašnjeno je na koji način su kategorije međusobno spojene. Kategorije „Ne znam / Bez odgovora“ pripojene su najfrekventnijoj kategoriji.

Statistički testovi provedeni su uz razinu rizika od 5%.

5.4.Mjerni instrumenti

5.4.1. Zavisna (kriterijska) varijabla: radni status

Radni status ispitanika određen je prema njegovom/njezinom navodu. Ispitanicima je postavljeno pitanje „Koji je vaš radni status?“ te su im ponuđeni odgovori 1) Zaposlen kod nekog, 2) Samostalno zaposleni – slobodne profesije, 3) Samostalno zaposleni – poljoprivredno gospodarstvo, farma, 4) Samostalno zaposleni – vlasnici poduzeća ili obrta, 5) Nezaposleni, 6) Kućanice, 7) Učenici i studenti, 8) U mirovini, 9) Novaci u vojsci (neaktivni), a dopušteno je i da odbiju odgovoriti ili kažu da ne znaju.

Iako se svrstavanje ispitanika u kategorije temelji na njihovom samoodređenju, ovakva široka klasifikacija smanjuje mogućnost pogrešnog kategoriziranja.

S obzirom da je u fokusu ovog rada određivanje koje karakteristike doprinose većoj šansi pripadanja u kategoriju nezaposlenih osoba, kreirana je nova varijabla koja *neaktivne osobe*, to jest, kategorije 6) kućanice, 7) učenici i studenti, 8) u mirovini, 9) novaci u vojsci (neaktivni) kao i one koji nisu dali odgovor na ovo pitanje *isključuje iz analize*, a *zaposlene ili samozaposlene*, to jest, kategorije 1) zaposlen kod nekog, 2) samostalno zaposleni – slobodne profesije, 3) samostalno zaposleni – poljoprivredno gospodarstvo, farma, 4) samostalno zaposleni – vlasnici poduzeća ili obrta *svrstava u jednu kategoriju – zaposleni*, dok kategorija 5) nezaposleni ostaje samostalna kategorija koja je u fokusu interesa.

5.4.2. Nezavisne (prediktorske) varijable

Spol ispitanika s kategorijama 1) muški i 2) ženski anketari su zabilježili prepoznavanjem po fizičkom izgledu, bez postavljanja pitanja ispitaniku.

Dob ispitanika zabilježena je u apsolutnom broju, s obzirom na to koliko godina je ispitanik navršio u trenutku anketiranja. *Dob* je jedini kvantitativni prediktor.

Obrazovanje je određeno prema najvišem završenom stupnju. Ispitanika se originalno svrstalo u jedno od 11 kategorija obrazovanja: 1) bez škole ili 1 do 3 razreda osnovne škole, 2) 4 do 7 razreda osnovne škole, 3) osnovna škola, 4) jednogodišnja ili dvogodišnja stručna škola, 5) trogodišnja stručna škola za zanimanja, 6) četverogodišnja stručna škola za zanimanja, 7) gimnazija, 8) viša škola, prvi stupanj fakulteta, 9) fakultet, akademija, visoka škola, 10) magisterij, 11) doktorat te je dopušteno ne odgovoriti ili ne znati odgovor. Za potrebe analize, obrazovanje je grupirano u 3 razreda: *niže*, koje obuhvaća kategorije 1) bez škole ili 1 do 3 razreda osnovne škole, 2) 4 do 7 razreda osnovne škole, 3) osnovna škola te odgovara kategorijama NSKO⁹ 0, 1 i 2 odnosno ISCED¹⁰ 0, 1 i 2, *srednje*, koje obuhvaća kategorije 4) jednogodišnja ili dvogodišnja stručna škola, 5) trogodišnja stručna škola za zanimanja, 6) četverogodišnja stručna škola za zanimanja, 7) gimnazija, odnosno NSKO/ISCED 3 i 4 (NSKO/ISCED 4 ne postoji kao kategoriju u ovoj varijabli) te *više*, koje obuhvaća kategorije 8) viša škola, prvi stupanj fakulteta, 9) fakultet, akademija, visoka škola, 10) magisterij, 11) doktorat, što odgovara kategorijama NSKO/ISCED 5-8. Ovakva agregirana podjela na niže, srednje i više obrazovanje u skladu je s agregiranom podjelom koju koristi Eurostat.

Zanimanje ispitanika određeno je na temelju njegovog izbora između 8 kategorija: 1) slobodna profesija, 2) stručnjaci i intelektualci, 3) viši menadžment, viši rukovoditelji, direktori, 4) srednji menadžment, 5) službenici, 6) kvalificirani radnici, uključujući i bolničke sestre, 7) nekvalificirani i niskokvalificirani radnici, i 8) poljoprivrednici.

Mjesto stanovanja s kategorijama selo i grad, *veličina naselja*, s kategorijama 1) do 2000 stanovnika, 2) 2 001 -10 000 stanovnika, 3) 10 001 – 100 000 stanovnika i 4) 100 001 i više stanovnika, te podjela prema *regijama* na 1) Zagreb i okolica, 2) Sjeverna Hrvatska, 3) Slavonija, 4) Lika i Banovina, 5) Istra, Primorje i Gorski Kotar te 6) Dalmacija odredili su anketari, s obzirom na mjesto stanovanja anketiranog ispitanika.

Bračni status osobe određen je prema vlastitom odabiru između 4 kategorija 1) Oženjen – udana, 2) Neoženjen – neudana, 3) Rastavljen – rastavljena i 4) Udovac – udovica.

⁹NSKO = Nacionalna standardna klasifikacija obrazovanja, prema: https://narodne-novine.nn.hr/clanci/sluzbeni/2001_11_105_1734.html

¹⁰ISCED = International Standard Classification of Education, prema : [http://ec.europa.eu/eurostat/statistics-explained/index.php/International_Standard_Classification_of_Education_\(ISCED\)](http://ec.europa.eu/eurostat/statistics-explained/index.php/International_Standard_Classification_of_Education_(ISCED))

Suživot sa vlastitom maloljetnom djecom je varijabla kreirana na temelju dviju varijabli – na temelju varijable koje mjeri s kim u kućanstvu žive ispitanici te na temelju varijable koja određuje broj maloljetnih osoba koje žive u kućanstvu ispitanika. Ako je osoba odgovorila da živi u kućanstvu s vlastitom djecom te u tom kućanstvu žive maloljetna djeca, ispitanik je svrstan u kategoriju 1) osoba živi s vlastitom maloljetnom djecom, a ukoliko ne zadovoljava oba kriterija, ispitanik je svrstan u kategoriju 2) osoba ne živi s vlastitom maloljetnom djecom. Sve osobe iznad 55 godina svrstane su u kategoriju 2) osoba ne živi s vlastitom maloljetnom djecom. Ovo je arbitrarna granica koja je postavljena kako bi se eliminirale osobe koje bi svrstali u kategoriju 1 jer žive u višegeneracijskom kućanstvu s vlastitom odraslom djecom i maloljetnim unucima.

5.5.Opis korištenih metoda

Kao što je već spomenuto, na temelju podataka želimo procijeniti vjerojatnost da je osoba nezaposlena ako su nam poznate njene sljedeće sociodemografske karakteristike: dob, obrazovanje, zanimanje, tip naselja u kojem živi, veličina naselja u kojem živi, regija, bračni status i suživot sa vlastitom maloljetnom djecom. Modeli su testirani u tri točke mjerenja – agregirani podaci od 2008. do 2010. godine, zatim od 2011. do 2013. i od 2014. do 2016.

Za potrebe izrade predikcijskog modela koji bi objašnjavao koje karakteristike doprinose većoj šansi da osoba bude nezaposlena, u obzir su uzete samo dvije kategorije radnog statusa – zaposleni te nezaposleni. Sve neaktivne osobe na ovoj varijabli proglašene su *missing* vrijednostima. S obzirom na to da je kriterij (radni status) binarna kategorijalna varijabla, a prediktori kontinuirana (dob) i kategorijalne varijable (svi ostali prediktori osim dobi) kao prikladna analiza odabrana je binarna logistička regresija.

Binarna logistička regresija je oblik regresijske analize koja se koristi za procjenu vjerojatnosti zbivanja nekog fenomena u slučajevima kad je zavisna varijabla dihotomna te označena vrijednostima 0 i 1, a temelji se na *logit* funkciji (Halmi, 2013.).

Prije provedbe same analize, potrebno je odrediti koje kategorije varijabli će biti referentne. Referentne kategorije su one s kojima uspoređujemo sve ostale kategorije. S obzirom da su nam nezaposlene osobe u središtu interesa, za referentnu kategoriju kriterijske varijable postavljena je kategorija zaposlenih osoba. S obzirom da imamo više nominalnih prediktora, jednostavnosti radi, njihove kategorije kodirat ćemo tako da referentna kategorija bude odabrana uvijek po istom principu – kao ona s najmanjim kodom. Slijedi pregled

varijabli, kodova i referentnih kategorija. Za referentnu kategoriju svakog prediktora izabrana je ona kategorija koja je imala najviši udio zaposlenih ispitanika, osim u slučaju regije, kad je, zbog svoje veličine i važnosti, za referentnu kategoriju izabrana regija Zagreb i okolica, iako regija Istra, Primorje i Gorski kotar ima nešto viši udio zaposlenih.

Zavisna varijabla, kriterij je:

- Radni status, s kategorijama
 - 0 = zaposleni (referentna kategorija)
 - 1 = nezaposleni

Nezavisne varijable, prediktori su:

- Dob – jedina kvantitativna varijabla
- Spol
 - 1 = Muškarac (referentna kategorija)
 - 2 = Žena
- Obrazovanje
 - 1 = Više (referentna kategorija)
 - 2 = Srednje
 - 3 = Niže
- Zanimanje
 - 1 = viši menedžment, viši rukovoditelji, direktori (referentna kategorija)
 - 2 = slobodna profesija
 - 3 = stručnjaci i intelektualci
 - 4 = srednji menadžment
 - 5 = službenici
 - 6 = kvalificirani radnici, uključujući i bolničke sestre
 - 7 = nekvalificirani i niskokvalificirani radnici
 - 8 = poljoprivrednici i ribari.
- Tip naselja
 - 1 = Grad (referentna kategorija)
 - 2 = Selo
- Veličina naselja
 - 1 = 100 001 i više stanovnika (referentna kategorija)
 - 2 = 10 001 - 100 000 stanovnika
 - 3 = 2 001 - 10 000 stanovnika


- 4 = do 2000 stanovnika
- Regija
 - 1 = Zagreb i okolica (referentna kategorija)
 - 2 = Sjeverna Hrvatska
 - 3 = Slavonija
 - 4 = Lika i Banovina
 - 5 = Istra, Primorje i Gorski Kotar
 - 6 = Dalmacija
- Bračni status
 - 1 = Oženjen – udana (referentna kategorija)
 - 2 = Neoženjen - neudana
 - 3 = Rastavljen - rastavljena
 - 4 = Udovac – udovica
- Suživot sa vlastitom malodobnom djecom
 - 1 = Osoba živi s vlastitom maloljetnom djecom (referentna kategorija)
 - 2 = Osoba ne živi s vlastitom maloljetnom djecom

Svaka kategorija, osim referentnih, je jedan prediktor čiji se utjecaj testira u modelu. Iznimka je kategorija 4 = do 2000 stanovnika u varijabli Veličina naselja koja se potpuno poklapa s kategorijom 2 = Selo u varijabli Tip naselja, te se njega ne testira ponovno.

6. Rezultati

6.1.Prva točka mjerenja - 2008.-2010.

Kao što je vidljivo u slici 7, u prvoj točki mjerenja, agregiranim podacima od 2008. do 2010. godine, među radno aktivnim ispitanicima, jedna je četvrtina nezaposlenih.



Slika 7. Deskripcija zavisne varijable –podjela radno aktivnog stanovništva na agregiranim podacima 2008.-2010. godina

Sada ćemo najprije pogledati raspodjelu udjela zaposlenih i nezaposlenih ispitanika po pojedinim kategorijama nezavisnih varijabli.

Tablica 5. Kontingencijska tablica zavisne varijable radni status s prediktorskih varijabli na agregiranim podacima 2008.-2010. godina

		Zaposleni		Nezaposleni		Ukupno	
		N	(%)	N	(%)	N	(%)
Spol	Muškarac	7650	77,8%	2186	22,2%	9836	100,0%
	Žena	5578	71,7%	2206	28,3%	7784	100,0%
Obrazovanje	Niže	1632	53,8%	1404	46,2%	3036	100,0%
	Srednje	8719	76,7%	2645	23,3%	11364	100,0%
	Više	2877	89,3%	344	10,7%	3220	100,0%
Zanimanje	Slobodna profesija	54	83,6%	11	16,4%	64	100,0%
	Stručnjaci i intelektualci	1323	92,4%	108	7,6%	1431	100,0%
	Viši menedžment, viši rukovoditelji, direktori	535	94,6%	31	5,4%	566	100,0%
	Srednji menedžment	907	93,2%	66	6,8%	973	100,0%
	Službenici	2518	89,1%	307	10,9%	2825	100,0%
	Kvalificirani radnici, uključujući i bolničke sestre	6553	69,9%	2820	30,1%	9373	100,0%
	Nekvalificirani i niskokvalificirani radnici	994	52,2%	910	47,8%	1904	100,0%
	Poljoprivrednici i ribari	343	71,5%	137	28,5%	480	100,0%
Tip naselja	Selo	4692	68,9%	2114	31,1%	6806	100,0%

	Grad	8536	78,9%	2278	21,1%	10814	100,0%
Veličina naselja	Do 2000 stanovnika	4692	68,9%	2114	31,1%	6806	100,0%
	2 001 - 10 000 stanovnika	2087	72,4%	796	27,6%	2883	100,0%
	10 001 - 100 000 stanovnika	2707	79,5%	700	20,5%	3407	100,0%
	100 001 i više stanovnika	3742	82,7%	782	17,3%	4524	100,0%
Regija	Zagreb i okolica	3679	80,5%	892	19,5%	4571	100,0%
	Sjeverna Hrvatska	2347	75,3%	771	24,7%	3118	100,0%
	Slavonija	1949	66,9%	966	33,1%	2914	100,0%
	Lika i Banovina	891	63,7%	507	36,3%	1398	100,0%
	Istra, Primorje i Gorski Kotar	1947	84,4%	359	15,6%	2306	100,0%
	Dalmacija	2416	72,9%	898	27,1%	3313	100,0%
Bračni status	Oženjen - udana	8876	78,0%	2501	22,0%	11377	100,0%
	Neoženjen - neudana	3417	69,0%	1535	31,0%	4951	100,0%
	Rastavljen - rastavljena	677	73,5%	244	26,5%	921	100,0%
	Udovac - udovica	259	69,7%	112	30,3%	371	100,0%
Suživot sa vlastitom malodobnom djecom	Osoba živi s vlastitom maloljetnom djecom	5727	79,4%	1486	20,6%	7213	100,0%
	Osoba ne živi s vlastitom maloljetnom djecom	7502	72,1%	2906	27,9%	10408	100,0%

Vidljivo je da je među muškim ispitanicima nešto niži udio nezaposlenih u odnosu na udio nezaposlenih među ispitanicama. Što se pak tiče obrazovanja, što je stupanj postignutog obrazovanja viši, niži je udio nezaposlenih. Najniži udio nezaposlenih bilježi grupa zanimanja višeg menedžmenta, viših rukovoditelja i direktora, a slijede ih srednji menadžment, stručnjaci i intelektualci te zatim službenici. Najveći udio nezaposlenih je među ispitanicima koji pripadaju grupi niskokvalificiranih i nekvalificiranih radnika. Porastom veličine naselja, smanjuje se udio nezaposlenih, stoga je i udio nezaposlenih niži u urbanom nego što je u ruralnom području. Što se tiče regije, najmanje je nezaposlenih ispitanika u Istri, Primorju i Gorskom Kotaru, a potom slijedi Zagreb i okolica, zatim Sjeverna Hrvatska, Dalmacija, Slavonija te je na začelju Lika i Banovina. Oženjeni ispitanici i udane ispitanice imaju nešto niži udio nezaposlenih od ostalih kategorija, a oni koji ne žive s vlastitom malodobnom djecom češće su nezaposleni od onih koji s njima žive.

Kako bismo provjerili može li se nezaposlenost objasniti sociodemografskim karakteristikama, najprije je provedena bivarijatna binarna logistička regresija sa svakim od prediktora posebno. Budući da se svaki od njih pokazao statistički značajnim, provedena je multivarijatna binarna logistička regresija uz korištenje metode *Enter*, koja podrazumijeva istovremeno uključivanje svih prediktorskih varijabli u analizu.

Tablica 6. Testiranje koeficijenata modela; binarna logistička regresija; opći model, 2008.-2010.

	Hi-kvadrat	Stupnjevi slobode	p
<i>Step</i>	2553,395	23	<0,05
<i>Block</i>	2553,395	23	<0,05
<i>Model</i>	2553,395	23	<0,05

Iz tablice 6 vidimo da hi-kvadrat iznosi 2569,358, model ima 23 stupnja slobode (jedan stupanj slobode za svaku kategoriju nezavisnih varijabli koje se uspoređuju s pripadajućom referentnom kategorijom) te je statistički značajan ($p < 0,05$) na razini rizika od 5% – time odbacujemo nultu hipotezu da su regresijski koeficijenti svih prediktora jednaki nuli, odnosno, na agregiranim podacima 2008.-2010. godine nacionalno reprezentativnog uzorka Republike Hrvatske, nezaposlenost se može objasniti odabranim sociodemografskim varijablama.

Tablica 7. Sažetak modela; binarna logistička regresija; opći model, 2008.-2010.

-2 Log likelihood	Cox&Snell R^2	Nagelkerke R^2
17227,747	0,135	0,200

Model je prilično slabe prediktivne snage, *Cox&Snell* R^2 iznosi 0,135, a *Nagelkerke* R^2 0,200.

Tablica 8. Klasifikacijska tablica; binarna logistička regresija; opći model, 2008.-2010.

Opaženo		Predviđeno		Točno procijenjeno
		Radni status		
		Zaposleni	Nezaposleni	
Radni status	Zaposleni	12583	645	95,1
	Nezaposleni	3529	861	19,6
Ukupni postotak				76,3

Model s ovim prediktorima ispravno prepoznaje 76,3% slučajeva, što je 1,2% više od ispravno prepoznatih slučajeva u nul-modelu (model bez prediktora) – 75,1%. Specifičnost modela iznosi 95,1%, to jest, 95,1% ispitanika koji su zaposleni, model je ispravno svrstao u zaposlene. Međutim, osjetljivost iznosi 19,6%, to jest, samo toliki udio nezaposlenih osoba bi prema modelu ispravno bilo svrstano u kategoriju nezaposlenih osoba. Slijedi pregled prediktora uključenih u model.

Tablica 9. Prediktori uključeni u model sa zavisnom varijablom radni status; binarna logistička regresija; opći model, 2008.-2010.

	Prediktori	B	S.E.	Wald	df	p	OR	95% C.I. for OR	
								Lower	Upper
Spol	Ženski spol	0,661	0,040	273,231	1	<0,05	1,936	1,790	2,094
Obrazovanje	Više			151,452	2	<0,05			
	Srednje	0,008	0,085	0,010	1	0,921	1,008	0,853	1,192
	Niže	0,729	0,101	52,413	1	<0,05	2,074	1,702	2,526
Zanimanje	Viši menedžment, viši rukovoditelji, direktori			548,106	7	<0,05			
	Slobodna profesija	1,096	0,392	7,831	1	<0,05	2,992	1,389	6,446
	stručnjaci i intelektualci	0,176	0,216	0,670	1	0,413	1,193	0,782	1,820
	Srednji menadžment	0,196	0,228	0,739	1	0,390	1,216	0,778	1,900
	Službenici	0,544	0,200	7,424	1	<0,05	1,724	1,165	2,550
	Kvalificirani radnici, uključujući i bolničke sestre	1,778	0,194	83,706	1	<0,05	5,919	4,044	8,664
	Nekvalificirani i niskokvalificirani radnici	1,971	0,204	93,653	1	<0,05	7,178	4,816	10,700
	Poljoprivrednici i ribari	1,244	0,224	30,883	1	<0,05	3,471	2,238	5,384
Tip naselja	Selo	0,362	0,060	36,935	1	<0,05	1,437	1,278	1,615
Veličina naselja	100 001 i više stanovnika			19,563	2	<0,05			
	10 001 - 100 000 stanovnika	-0,035	0,067	0,270	1	0,603	0,966	0,846	1,102
	2 001 - 10 000 stanovnika do 2000 stanovnika	0,230	0,068	11,393	1	<0,05	1,259	1,101	1,439
Regija	Zagreb i okolica			238,447	5	<0,05		0,758	0,987
	Sjeverna Hrvatska	-0,146	0,067	4,663	1	<0,05	0,865	1,336	1,717
	Slavonija	0,415	0,064	42,108	1	<0,05	1,514	1,488	2,024
	Lika i Banovina	0,551	0,078	49,363	1	<0,05	1,735	0,543	0,727
	Istra, Primorje i Gorski Kotar	-0,465	0,075	38,919	1	<0,05	0,628	1,144	1,457
	Dalmacija	0,256	0,062	17,172	1	<0,05	1,291		
Bračni status	Oženjen – udana			80,483	3	<0,05		1,506	1,900
	Neoženjen - neudana	0,526	0,059	78,665	1	<0,05	1,692	1,048	1,474
	Rastavljen - rastavljena	0,217	0,087	6,236	1	<0,05	1,243	0,733	1,217
	Udovac – udovica	-0,057	0,129	0,196	1	0,658	0,944	1,233	1,497
Suživot s vlastitom malodobnom djecom	Osoba ne živi s vlastitom malodobnom djecom	0,306	0,050	38,321	1	<0,05	1,359	1,000	1,008
Dob	Dob u godinama	0,004	0,002	3,205	1	0,073	1,004		
	Konstanta	-3,800	0,215	311,940	1	<0,05	0,022	0,758	0,987

B = Logistički koeficijent; S.E.= standardne pogreške logističkih koeficijenata; Waldovi statistici (distribucija po χ^2); OR = Omjeri šansi (engl. *oddsratio*), odnosno promjene u šansama kriterija za jednu jedinicu promjene u prediktoru; 95% C.I. for OR = 95%-tni intervali pouzdanosti za omjere šansi

Statistički značajni prediktori za nezaposlenost su: ženski spol, niže obrazovanje, sljedeće grupe zanimanja: slobodna profesija, službenici, kvalificirani radnici, uključujući i

bolničke sestre, nekvalificirani i niskokvalificirani radnici te poljoprivrednici i ribari, seoski tip naselja, prebivalište u naselju veličine 2 001 - 10 000 stanovnika, prebivalište u regijama Sjeverna Hrvatska, Slavonija, Lika i Banovina, Istra, Primorje i Gorski Kotar te Dalmacija, bračni status neoženjen - neudata te rastavljen - rastavljena, kao i suživot bez vlastite malodobne djece. Dob, jedini kvantitativan prediktor, nije statistički značajan.

Uvidom u beta koeficijente utvrđujemo da žene imaju 1,9 puta veću šansu od muškaraca da budu nezaposlene, ako ostale varijable u modelu ostanu konstantne, a usporedbi s osobama višeg obrazovanja, osobe nižeg obrazovanja također imaju 2puta veću šansu da budu u statusu nezaposlene osobe. Što se tiče zanimanja, u usporedbi s referentnom kategorijom, višim menedžmentom, višim rukovoditeljima i direktorima, osobe sa sljedećem kategorijama zanimanja imaju veću šansu da budu nezaposlene: slobodne profesije 3 puta, službenici 1,7 puta, kvalificirani radnici 5,9 puta, nekvalificirani i niskokvalificirani radnici 7,2 puta, a poljoprivrednici i ribari 3,5 puta.


Stanovnici sela, u odnosu na stanovnike grada imaju 1,4 puta veću šansu da budu nezaposleni, dok, u odnosu na stanovnike veličine naselja većeg od 100 000 stanovnika, stanovnici naselja veličine 2 001 - 10 000 stanovnika imaju 1,3 puta veću šansu da budu nezaposleni.

Što se pak tiče regije, u odnosu na stanovnike Zagreba i okolice, stanovnici sljedećih regija imaju značajno više šanse da budu nezaposleni: Slavonija 1,5 puta, Lika i Banovina 1,7 puta te Dalmacija 1,3 puta; dok stanovnici Sjeverne Hrvatske imaju 13%, a stanovnici Istre, Primorja i Gorskog Kotara 37% manje šanse da budu nezaposleni.

U odnosu na osobe u braku, neoženjeni i neudate imaju 1,7 puta, a rastavljeni 1,2 puta veće šanse da budu nezaposleni. U odnosu na one koji ne žive s vlastitom malodobnom djecom, osobe koje žive s vlastitom malodobnom djecom imaju 1,3 puta veću šansu da budu u statusu nezaposlene osobe.

6.2.Druga točka mjerenja - 2011.-2013.

U prvoj točki mjerenja, agregiranim podacima od 2011. do 2013. godine, nezaposleni ispitanici čine 34,0% radno aktivnih ispitanika, kao što je prikazano na slici 8.



Slika 8. Deskripcija zavisne varijable – podjela radno aktivnog stanovništva na agregiranim podacima 2011.-2013. godina

Sada ćemo pogledati kategorije prediktorskih varijabli s obzirom na zaposlenost.

Tablica 10. Kontingencijska tablica zavisne varijable radni status s prediktorskih varijabli na agregiranim podacima 2011.-2013. godina

		Zaposleni		Nezaposleni		Ukupno	
		N	(%)	N	(%)	N	(%)
Spol	Muškarac	6689	68,6%	3068	31,4%	9757	100,0%
	Žena	5013	62,9%	2963	37,1%	7976	100,0%
Obrazovanje	Niže	1314	42,3%	1793	57,7%	3107	100,0%
	Srednje	7846	68,1%	3682	31,9%	11528	100,0%
	Više	2543	82,1%	555	17,9%	3098	100,0%
Zanimanje	Slobodna profesija	46	77,8%	13	22,2%	60	100,0%
	Stručnjaci i intelektualci	1153	84,1%	218	15,9%	1371	100,0%
	Viši menedžment, viši rukovoditelji, direktori	362	91,6%	33	8,4%	395	100,0%
	Srednji menedžment	746	88,2%	100	11,8%	845	100,0%
	Službenici	2033	80,9%	480	19,1%	2513	100,0%
	Kvalificirani radnici, uključujući i bolničke sestre	6133	62,4%	3688	37,6%	9821	100,0%
	Nekvalificirani i niskokvalificirani radnici	961	41,7%	1341	58,3%	2301	100,0%
	Poljoprivrednici i ribari	270	63,3%	157	36,7%	426	100,0%
Tip naselja	Selo	4107	58,6%	2906	41,4%	7013	100,0%
	Grad	7596	70,9%	3124	29,1%	10720	100,0%
Veličina	Do 2000 stanovnika	4107	58,6%	2906	41,4%	7013	100,0%

naselja	2 001 - 10 000 stanovnika	1880	64,7%	1026	35,3%	2906	100,0%
	10 001 - 100 000 stanovnika	2419	70,5%	1011	29,5%	3430	100,0%
	100 001 i više stanovnika	3297	75,2%	1087	24,8%	4384	100,0%
Regija	Zagreb i okolica	3368	73,9%	1187	26,1%	4556	100,0%
	Sjeverna Hrvatska	1984	64,0%	1116	36,0%	3100	100,0%
	Slavonija	1708	57,4%	1268	42,6%	2976	100,0%
	Lika i Banovina	838	56,1%	655	43,9%	1493	100,0%
	Istra, Primorje i Gorski Kotar	1735	74,7%	587	25,3%	2323	100,0%
	Dalmacija	2069	62,9%	1218	37,1%	3286	100,0%
Bračni status	Oženjen - udana	7923	70,5%	3315	29,5%	11238	100,0%
	Neoženjen - neudana	2891	56,8%	2198	43,2%	5089	100,0%
	Rastavljen - rastavljena	663	63,4%	383	36,6%	1046	100,0%
	Udovac - udovica	226	62,6%	135	37,4%	361	100,0%
Suživot sa vlastitom malodobnom djecom	Osoba živi s vlastitom maloljetnom djecom	4941	71,3%	1991	28,7%	6932	100,0%
	Osoba ne živi s vlastitom maloljetnom djecom	6761	62,6%	4040	37,4%	10801	100,0%

Odnosi su vrlo slični onima koje smo dobili na agregiranim podacima od 2008. do 2010. godine – veći je udio nezaposlenih ispitanica nego ispitanika, udio nezaposlenih smanjuje se što je postignut viši stupanj obrazovanja, zanimanja koja intuitivno doživljavamo višima imaju niži udio nezaposlenih ispitanika. Manje je nezaposlenih ispitanika u urbanom području te u naseljima s više stanovnika, kao i među oženjenim ispitanicima i udatima ispitanicama te onima koji žive s vlastitom malodobnom djecom. Odnosi među regijama se nisu značajno promijenili, osim što Istra i Zagreb imaju gotovo jednak udio nezaposlenih ispitanika (u prethodnoj točki mjerenja, regija Istra, Primorje i Gorski Kotar imala je nešto veći udio zaposlenih od Zagreba i okolice), razlika između Sjeverne Hrvatske i Dalmacije također se smanjila, kao i između Slavonije i Like i Banovine.

I u ovoj točki mjerenja provjeravamo može li se nezaposlenost objasniti sociodemografskim karakteristikama te je najprije provedena bivarijatna binarna logistička regresija sa svakim od prediktora posebno u kojoj se svaki od njih pokazao statistički značajnim. Zatim je provedena multivarijatna binarna logistička regresija uz korištenje metode *Enter* (podrazumijeva istovremeno uključivanje svih prediktorskih varijabli u analizu).

Tablica 11. Testiranje koeficijenata modela; binarna logistička regresija; opći model, 2011.-2013.

	Hi-kvadrat	Stupnjevi slobode	p
<i>Step</i>	2549,427	23	<0,05
<i>Block</i>	2549,427	23	<0,05
<i>Model</i>	2549,427	23	<0,05

Iz tablice 11 vidimo da hi-kvadrat iznosi 2549,427, model ima 23 stupnja slobode (jedan stupanj slobode za svaku kategoriju nezavisnih varijabli koje se uspoređuju s pripadajućom referentnom kategorijom) te je statistički značajan ($p < 0,05$) na razini rizika od 5% – time odbacujemo nultu hipotezu da su regresijski koeficijenti svih prediktora jednaki nuli, odnosno, na agregiranim podacima 2011.-2013. godine nacionalno reprezentativnog uzorka Republike Hrvatske, nezaposlenost se može objasniti odabranim sociodemografskim varijablama.

Tablica 12. Sažetak modela; binarna logistička regresija; opći model, 2011.-2013.

-2 Log likelihood	Cox&Snell R^2	Nagelkerke R^2
20185,644	0,134	0,185

I ovaj model je prilično slabe prediktivne snage, $Cox\&Snell R^2$ iznosi 0,134, a $Nagelkerke R^2$ 0,185.

Tablica 13. Klasifikacijska tablica; binarna logistička regresija; opći model, 2011.-2013.

Opaženo		Predviđeno		Točno procijenjeno (%)
		Radni status		
		Zaposleni	Nezaposleni	
Radni status	Zaposleni	10326	1377	88,2
	Nezaposleni	3941	2089	34,6
Ukupni postotak				70,0

Model s ovim prediktorima ispravno prepoznaje 70,0% slučajeva, što je 4,0% više od ispravno prepoznatih slučajeva u nul-modelu (model bez prediktora) – 66,0%. Specifičnost modela iznosi 88,2%, to jest, 88,2% ispitanika koji su zaposleni, model je ispravno svrstao u zaposlene. Međutim, osjetljivost iznosi 34,6%, to jest, samo toliki udio nezaposlenih osoba bi prema modelu ispravno bilo svrstano u kategoriju nezaposlenih osoba.

Tablica 14. Prediktori uključeni u model sa zavisnom varijablom radni status; binarna logistička regresija; opći model, 2011.-2013.

	Prediktori	B	S.E.	Wald	df	p	OR	95% C.I. for OR	
								Lower	Upper
Spol	Ženski spol	0,489	0,036	182,032	1	<0,05	1,630	1,519	1,750
Obrazovanje	Više			192,818	2	<0,05			
	Srednje	0,140	0,074	3,545	1	<0,05	1,150	0,994	1,330
	Niže	0,947	0,092	105,130	1	<0,05	2,579	2,152	3,091
Zanimanje	Viši menedžment, viši rukovoditelji, direktori			377,305	7	<0,05			
	Slobodna profesija	1,213	0,370	10,754	1	<0,05	3,363	1,629	6,943
	stručnjaci i intelektualci	0,587	0,201	8,501	1	<0,05	1,798	1,212	2,667
	Srednji menadžment	0,307	0,214	2,057	1	0,152	1,360	0,893	2,070
	Službenici	0,712	0,193	13,528	1	<0,05	2,037	1,394	2,977
	Kvalificirani radnici, uključujući i bolničke sestre	1,540	0,190	65,500	1	<0,05	4,666	3,213	6,775
	Nekvalificirani i niskokvalificirani radnici	1,775	0,199	79,447	1	<0,05	5,898	3,992	8,713
	Poljoprivrednici i ribari	1,066	0,220	23,511	1	<0,05	2,903	1,887	4,467
Tip naselja	Selo	0,306	0,054	32,649	1	<0,05	1,358	1,223	1,508
Veličina naselja	100 001 i više stanovnika			6,659	2	<0,05			
	10 001 - 100 000 stanovnika	-0,096	0,060	2,544	1	0,111	0,909	0,808	1,022
	2 001 - 10 000 stanovnika do 2000 stanovnika	0,051	0,062	0,667	1	0,414	1,052	0,932	1,188
Regija	Zagreb i okolica			206,096	5	<0,05			
	Sjeverna Hrvatska	0,117	0,061	3,634	1	0,057	1,124	0,997	1,268
	Slavonija	0,510	0,059	75,203	1	<0,05	1,666	1,484	1,870
	Lika i Banovina	0,451	0,073	38,552	1	<0,05	1,570	1,362	1,811
	Istra, Primorje i Gorski Kotar	-0,230	0,064	12,814	1	<0,05	0,795	0,701	0,901
	Dalmacija	0,434	0,056	58,880	1	<0,05	1,543	1,381	1,723
Bračni status	Oženjen – udana			125,336	3	<0,05			
	Neoženjen - neudana	0,587	0,054	119,464	1	<0,05	1,798	1,619	1,998
	Rastavljen - rastavljena	0,277	0,074	13,971	1	<0,05	1,319	1,141	1,525
	Udovac – udovica	-0,095	0,123	0,597	1	0,440	0,909	0,714	1,157
Suživot s vlastitom malodobnom djecom	Osoba ne živi s vlastitom malodobnom djecom	0,298	0,045	44,142	1	<0,05	1,347	1,233	1,470
Dob	Dob u godinama	-0,006	0,002	12,036	1	<0,05	0,994	0,990	0,997
	Konstanta	-2,948	0,207	203,338	1	<0,05	0,052		

B = Logistički koeficijent; S.E.= standardne pogreške logističkih koeficijenata; Waldovi statistici (distribucija po χ^2); OR = Omjeri šansi (engl. *oddsratio*), odnosno promjene u šansama kriterija za jednu jedinicu promjene u prediktoru; 95% C.I. for OR = 95%-tni intervali pouzdanosti za omjere šansi

Statistički značajni prediktori za nezaposlenost su: ženski spol, srednje obrazovanje, niže obrazovanje, sljedeće grupe zanimanja: slobodna profesija, stručnjaci i intelektualci,

službenici, kvalificirani radnici, uključujući i bolničke sestre, nekvalificirani i niskokvalificirani radnici te poljoprivrednici i ribari, seoski tip naselja, prebivalište u naselju veličine 10 001 - 100 000 stanovnika, prebivalište u regijama Slavonija, Lika i Banovina, Dalmacija te Istra, Primorje i Gorski Kotar, bračni status neoženjen - neudata te rastavljen - rastavljena, kao i suživot bez vlastite malodobne djece. Dob, jedini kvantitativan prediktor, također je statistički značajan.

Uvidom u beta koeficijente utvrđujemo da žene imaju 1,6 puta veću šansu od muškaraca da budu nezaposlene, ako ostale varijable u modelu ostanu konstantne. U usporedbi s osobama višeg obrazovanja, osobe nižeg obrazovanja imaju 2,6 puta veću šansu da budu u statusu nezaposlene osobe. Što se tiče zanimanja, u usporedbi s referentnom kategorijom, višim menedžmentom, višim rukovoditeljima i direktorima, sljedeće kategorije zanimanja imaju veću šansu da budu nezaposlene: slobodne profesije 3,4 puta, stručnjaci i intelektualci 1,8 puta (ova grupa zanimanja u prethodnoj točki mjerenja nije bila statistički značajan prediktor) službenici 2 puta, kvalificirani radnici 4,7 puta, nekvalificirani i niskokvalificirani radnici 5,9 puta, a poljoprivrednici i ribari 2,9 puta.

Stanovnici sela, u odnosu na stanovnike grada imaju 1,4 puta veću šansu da budu nezaposleni, dok u odnosu na stanovnike veličine naselja većeg od 100 000 stanovnika, stanovnici naselja veličine 10 001 - 100 000 stanovnika imaju 10% manju šansu da budu nezaposleni.


Što se pak tiče regije, u odnosu na stanovnike Zagreba i okolice, stanovnici svih drugih regija osim Istre, Primorja i Gorskog Kotara koja jedina nije značajni prediktor, imaju značajno više šanse da budu nezaposleni i to – Slavonija 1,7 puta, Lika i Banovina 1,6 puta te Dalmacija 1,5 puta. Život u regiji Istra, Primorje i Gorski Kotar, također je značajni prediktor, a stanovnici te regije, u usporedbi sa stanovnicima Zagreba i okolice, imaju 20% manju šansu da budu nezaposleni.

U odnosu na osobe u braku, neoženjeni i neudate imaju 1,8 puta, a rastavljeni 1,3 puta veće šanse da budu nezaposleni. U odnosu na one koji ne žive s vlastitom malodobnom djecom, osobe koje žive s vlastitom malodobnom djecom imaju 1,3 puta veću šansu da budu u statusu nezaposlene osobe.

Dob je također značajni prediktor nezaposlenosti. Za svaku godinu starosti više (da podsjetimo, u uzorak su uključene osobe u dobi od 15 do 64 godine), šansa za bivanje nezaposlenom osobom smanjuje se za 0,6%, ako su sve ostale varijable u modelu konstantne.

6.3. Treća točka mjerenja - 2014.-2016.

U trećoj točki mjerenja, agregiranim podacima od 2014. do 2016. godine, kategoriju nezaposlenih čini 5724 ispitanika, odnosno njih 28,9% od ukupnog uzorka radno aktivnih ispitanika (slika 9).



Slika 9. Deskripcija zavisne varijable – podjela radno aktivnog stanovništva na agregiranim podacima 2014.-2016. godina

Prikaz kategorija prediktorskih varijabli s obzirom na radni status možemo vidjeti u tablici 15.

Tablica 15. Kontingencijska tablica zavisne varijable radni status s prediktorskih varijabli na agregiranim podacima 2014.-2016. godina

		Zaposleni		Nezaposleni		Ukupno	
		N	(%)	N	(%)	N	(%)
Spol	Muškarac	7728	74,3%	2679	25,7%	10407	100,0%
	Žena	6366	67,6%	3045	32,4%	9411	100,0%
Obrazovanje	Niže	1085	43,6%	1406	56,4%	2491	100,0%
	Srednje	9193	71,6%	3641	28,4%	12834	100,0%
	Više	3816	84,9%	677	15,1%	4493	100,0%
Zanimanje	Slobodna profesija	74	81,9%	16	18,1%	90	100,0%
	Stručnjaci i intelektualci	1677	86,6%	260	13,4%	1937	100,0%

	Viši menadžment, viši rukovoditelji, direktori	460	91,2%	45	8,8%	505	100,0%
	Srednji menadžment	885	89,4%	105	10,6%	990	100,0%
	Službenici	2663	83,0%	545	17,0%	3208	100,0%
	Kvalificirani radnici, uključujući i bolničke sestre	7089	67,5%	3407	32,5%	10496	100,0%
	Nekvalificirani i niskokvalificirani radnici	1031	46,1%	1204	53,9%	2235	100,0%
	Poljoprivrednici i ribari	215	60,2%	142	39,8%	357	100,0%
Tip naselja	Selo	4557	64,6%	2502	35,4%	7059	100,0%
	Grad	9537	74,7%	3222	25,3%	12759	100,0%
Veličina naselja	Do 2000 stanovnika	4557	64,6%	2502	35,4%	7059	100,0%
	2 001 - 10 000 stanovnika	2296	70,0%	984	30,0%	3280	100,0%
	10 001 - 100 000 stanovnika	3065	74,4%	1057	25,6%	4122	100,0%
	100 001 i više stanovnika	4176	78,0%	1181	22,0%	5357	100,0%
Regija	Zagreb i okolica	4244	78,6%	1158	21,4%	5402	100,0%
	Sjeverna Hrvatska	2331	69,9%	1005	30,1%	3336	100,0%
	Slavonija	1936	61,0%	1238	39,0%	3174	100,0%
	Lika i Banovina	969	61,9%	596	38,1%	1565	100,0%
	Istra, Primorje i Gorski Kotar	1967	79,6%	504	20,4%	2471	100,0%
	Dalmacija	2647	68,4%	1224	31,6%	3871	100,0%
Bračni status	Oženjen - udana	9264	75,0%	3085	25,0%	12349	100,0%
	Neoženjen - neudana	3678	63,2%	2137	36,8%	5815	100,0%
	Rastavljen - rastavljena	865	69,1%	386	30,9%	1251	100,0%
	Udovac - udovica	287	71,3%	116	28,7%	403	100,0%
Suživot sa vlastitom malodobnom djecom	Osoba živi s vlastitom maloljetnom djecom	5589	75,6%	1807	24,4%	7396	100,0%
	Osoba ne živi s vlastitom maloljetnom djecom	8506	68,5%	3917	31,5%	12423	100,0%

Možemo primijetiti da su odnosi u udjelom nezaposlenih po pojedinim kategorija prediktora jednaki kao i u prvoj i drugoj točki mjerenja.

Također, i u ovoj točki mjerenja svi prediktori su se pokazali statističkim značajnima u pojedinačnim bivarijatna binarnim logističkim regresijama te je sljedeći korak provedba multivarijatne binarne logističke regresije uz korištenje metode *Enter*.

Tablica 16. Testiranje koeficijenata modela; binarna logistička regresija; opći model, 2014.-2016.

	Hi-kvadrat	Stupnjevi slobode	p
<i>Step</i>	2681,778	23	<0,05
<i>Block</i>	2681,778	23	<0,05
<i>Model</i>	2681,778	23	<0,05

Iz tablice 16 vidimo da hi-kvadrat iznosi 2681,778, model ima 23 stupnja slobode (jedan stupanj slobode za svaku kategoriju nezavisnih varijabli koje se uspoređuju s pripadajućom referentnom kategorijom) te je statistički značajan ($p < 0,05$) na razini rizika od 5% – time odbacujemo nultu hipotezu da su regresijski koeficijenti svih prediktora jednaki nuli, odnosno, na agregiranim podacima 2014.-2016. godine nacionalno reprezentativnog uzorka Republike Hrvatske, nezaposlenost se može objasniti odabranim sociodemografskim varijablama.

Tablica 17. Sažetak modela; binarna logistička regresija; opći model, 2014.-2016.

-2 Log likelihood	Cox&Snell R^2	Nagelkerke R^2
21143,890	0,127	0,181

Kao i u prethodne dvije točke mjerenja, model je prilično slabe prediktivne snage, $Cox\&Snell R^2$ iznosi 0,115, a $Nagelkerke R^2$ 0,164.

Tablica 18. Klasifikacijska tablica; binarna logistička regresija; opći model, 2014.-2016.

Opaženo		Predviđeno		Točno procijenjeno
		Radni status		
		Zaposleni	Nezaposleni	
Radni status	Zaposleni	13091	1004	92,9
	Nezaposleni	4244	1480	25,9
Ukupni postotak				73,5

Model s ovim prediktorima ispravno prepoznaje 73,5% slučajeva, što je 2,4% više od ispravno prepoznatih slučajeva u nul-modelu (model bez prediktora) – 71,1%. Specifičnost modela iznosi 92,9%, to jest, 92,9% ispitanika koji su zaposleni, model je ispravno svrstao u zaposlene. Međutim, osjetljivost iznosi 25,9%, to jest, samo toliki udio nezaposlenih osoba bi prema modelu ispravno bilo svrstano u kategoriju nezaposlenih osoba.

Tablica 19. Prediktori uključeni u model sa zavisnom varijablom radni status; binarna logistička regresija; opći model, 2014.-2016.

	Prediktori	B	S.E.	Wald	df	p	OR	95% C.I. for OR	
								Lower	Upper
Spol	Ženski spol	0,566	0,035	256,955	1	<0,05	1,762	1,644	1,888
Obrazovanje	Više			220,986	2	<0,05			
	Srednje	0,222	0,067	10,933	1	<0,05	1,249	1,095	1,425
	Niže	1,147	0,091	158,322	1	<0,05	3,148	2,633	3,764
Zanimanje	Viši menedžment, viši rukovoditelji, direktori			326,397	7	<0,05			
	Slobodna profesija	0,789	0,324	5,945	1	<0,05	2,202	1,167	4,153
	stručnjaci i intelektualci	0,322	0,174	3,400	1	0,065	1,379	0,980	1,942
	Srednji menadžment	0,116	0,191	0,372	1	0,542	1,123	0,773	1,633
	Službenici	0,448	0,168	7,109	1	<0,05	1,565	1,126	2,174
	Kvalificirani radnici, uključujući i bolničke sestre	1,243	0,166	56,285	1	<0,05	3,467	2,506	4,798
	Nekvalificirani i niskokvalificirani radnici	1,437	0,176	66,836	1	<0,05	4,208	2,982	5,938
	Poljoprivrednici i ribari	1,095	0,204	28,837	1	<0,05	2,990	2,005	4,460
Tip naselja	Selo	0,169	0,052	10,488	1	<0,05	1,184	1,069	1,312
Veličina naselja	100 001 i više stanovnika			7,164	2	<0,05			
	10 001 - 100 000 stanovnika	-0,150	0,057	6,915	1	<0,05	0,861	0,770	0,963
	2 001 - 10 000 stanovnika	-0,061	0,060	1,015	1	0,314	0,941	0,837	1,059
	do 2000 stanovnika								
Regija	Zagreb i okolica			295,363	5	<0,05			
	Sjeverna Hrvatska	0,175	0,061	8,209	1	<0,05	1,192	1,057	1,344
	Slavonija	0,738	0,058	163,960	1	<0,05	2,092	1,869	2,342
	Lika i Banovina	0,637	0,072	77,877	1	<0,05	1,891	1,641	2,178
	Istra, Primorje i Gorski Kotar	-0,092	0,065	2,005	1	0,157	0,912	,802	1,036
	Dalmacija	0,517	0,055	88,531	1	<0,05	1,676	1,505	1,867
Bračni status	Oženjen – udana			132,044	3	<0,05			
	Neoženjen - neudana	0,573	0,052	121,021	1	<0,05	1,773	1,601	1,964
	Rastavljen - rastavljena	0,294	0,071	17,371	1	<0,05	1,342	1,169	1,541
	Udovac – udovica	-0,209	0,123	2,892	1	<0,05	0,811	,637	1,032
Suživot s vlastitom malodobnom djecom	Osoba ne živi s vlastitom malodobnom djecom	0,239	0,044	29,091	1	<0,05	1,271	1,165	1,386
Dob	Dob u godinama	-0,006	0,002	12,591	1	<0,05	0,994	0,990	0,997
	Konstanta	-2,942	0,183	259,137	1	<0,05	0,053		

B = Logistički koeficijent; S.E.= standardne pogreške logističkih koeficijenata; Waldovi statistici (distribucija po χ^2); OR = Omjeri šansi (engl. *oddsratio*), odnosno promjene u šansama kriterija za jednu jedinicu promjene u prediktoru; 95% C.I. for OR = 95%-tni intervali pouzdanosti za omjere šansi

Statistički značajni prediktori za nezaposlenost su: ženski spol, srednje obrazovanje, niže obrazovanje, sljedeće grupe zanimanja: slobodna profesija, službenici, kvalificirani

radnici, uključujući i bolničke sestre, nekvalificirani i niskokvalificirani radnici te poljoprivrednici i ribari, seoski tip naselja, prebivalište u naselju veličine od 10 001 - 100 000 stanovnika, prebivalište u regijama Sjeverna Hrvatska, Slavonija, Lika i Banovina te Dalmacija, bračni status neoženjen - neudata te rastavljen - rastavljena, kao i suživot bez vlastite malodobne djece. Dob, jedini kvantitativan prediktor, također je statistički značajni prediktor.

Uvidom u beta koeficijente utvrđujemo da žene imaju 1,8 puta veću šansu od muškaraca da budu nezaposlene, ako ostale varijable u modelu ostanu konstantne. U usporedbi s osobama višeg obrazovanja, osobe srednjeg obrazovanja imaju 1,3, a nižeg obrazovanja 3,1 puta veću šansu da budu u statusu nezaposlene osobe. Što se tiče zanimanja, u usporedbi s referentnom kategorijom, višim menedžmentom, višim rukovoditeljima i direktorima, sljedeće kategorije zanimanja imaju veću šansu da budu nezaposlene: slobodne profesije 2,2 puta, službenici 1,6 puta, kvalificirani radnici 3,6 puta, nekvalificirani i niskokvalificirani radnici 4,2 puta, a poljoprivrednici i ribari 3 puta.

Stanovnici sela, u odnosu na stanovnike grada imaju 1,2 puta veću šansu da budu nezaposleni, dok, u odnosu na stanovnike veličine naselja većeg od 100 000 stanovnika, stanovnici naselja veličine 10 001 - 100 000 stanovnika imaju 14%, a stanovnici naselja veličine od 2 001 do 10 000 stanovnika 5% manju šansu da budu nezaposleni.

Što se pak tiče regije, u odnosu na stanovnike Zagreba i okolice, stanovnici svih drugih regija osim Istre, Primorja i Gorskog Kotara koja jedina nije značajni prediktor, imaju značajno više šanse da budu nezaposleni i to – Sjeverna Hrvatska 1,2 puta, Slavonija 2,1 puta, Lika i Banovina 1,9 puta te Dalmacija 1,7 puta.

U odnosu na osobe u braku, neoženjeni i neudate imaju 1,8 puta, a rastavljeni 1,3 puta veće šanse da budu nezaposleni. U odnosu na one koji ne žive s vlastitom malodobnom djecom, osobe koje žive s vlastitom malodobnom djecom imaju 1,3 puta veću šansu da budu u statusu nezaposlene osobe.

Za svaku godinu starosti više, šansa za bivanje nezaposlenom osobom smanjuje se za 0,6%, ako su sve ostale varijable u modelu konstantne.

7. Rasprava

Kretanje udjela nezaposlenosti u istraživanju Omnibus provedenom na nacionalno reprezentativnom uzorku Republike Hrvatske u dobi od 15 do 64 godine u promatrane tri točke mjerenja u skladu je s kretanjem udjela nezaposlenih prema službenim statistikama koje prate tržište rada – u prvoj točki mjerenja, agregiranim podacima od 2008. do 2010. godine, udio nezaposlenih osoba u ukupnom uzorku iznosi 12,6%, zatim je u drugoj točki mjerenja, agregiranim podacima od 2011. do 2013. vidljiv porast na 17,3% te ponovni pad (ali nedovoljni kako bi se udio vratio na onaj iz prve točke mjerenja) u trećoj točki mjerenja, agregiranim podacima od 2014. do 2016. godine kad udio nezaposlenih iznosi 15,9%. Stoga možemo zaključiti da ovo istraživanje dobro procjenjuje radni status stanovništva te se (uz određena ograničenja koja će biti navedena u idućem poglavlju) može koristiti za procjene sociodemografskih karakteristika nezaposlenih osoba.

Kao osnovnu hipotezu ovog rada, pretpostavili smo da se pripadanje kategoriji nezaposlenih osoba može objasniti prediktorskim sklopom koji se sastoji od sociodemografskih varijabli – spol, dob, regija, tip mjesta stanovanja (urbano ili ruralno područje), veličina mjesta stanovanja, obrazovanje i zanimanje te je ta hipoteza potvrđena u sve tri točke promatranja.

Što se tiče izvedenih hipoteza, djelomično je potvrđena prva izvedena hipoteza, da je niže obrazovanje prediktor koji višestruko povećava šansu da osoba bude nezaposlena. Naime, u prvoj točki mjerenja niže obrazovanje, u usporedbi s višim, povećava šansu da osoba bude nezaposlena 2,1 puta, u drugoj točki 2,6, a u trećoj najviše 3,1 puta. Možemo zaključiti da je vidljiv trend sve većeg efekta nižeg obrazovanja na to da osoba bude nezaposlena, ako su sve ostale varijable u modelu konstantne, pa tako efekt u prvoj točki nije višestruk, dok u drugoj i trećoj je.

Drugom izvedenom hipotezom pretpostavili smo da su kategorije zanimanja kvalificirani radnici te niskokvalificirani i nekvalificirani radnici prediktori koji višestruko povećavaju šansu da osoba bude nezaposlena. U prvoj točki mjerenja, pripadanje kategoriji kvalificiranih radnika povećava šansu da osoba bude zaposlena 5,9 puta, u drugoj 4,7 puta, a u trećoj 3,5 puta u odnosu na referentnu kategoriju, dok je za niskokvalificirane radnike šanse veća 7,2 puta u prvoj točki mjerenja, 5,9 puta u drugoj i 4,2 u trećoj. Time je potvrđena i druga izvedena hipoteza, a ova dva prediktora ujedno su i prediktori koji najviše od svih u modelu povećavaju šansu da osoba bude nezaposlena, u sve tri točke mjerenja.

Trećom izvedenom hipotezom pretpostavili smo da ženski spol i ruralni tip stanovanja umjereno povećavaju šansu da osoba bude nezaposlena. Kad bi vrijednosti na drugim varijablama ostale konstantne, ženski spol bi povećao šansu da osoba bude nezaposlena 1,9 puta u prvoj, 1,6 puta u drugoj i 1,8 puta u trećoj točki mjerenja, a ruralni tip naselja 1,4 puta u prvoj i drugoj te 1,2 puta u trećoj točki mjerenja. Iako su im efekti nešto drugačiji, to jest ženski spol nešto više povećava šansu da osoba bude nezaposlena od ruralnog tipa naselja, možemo prihvatiti hipotezu da ova dva prediktora imaju umjeren efekt.

Pretpostavili smo da život u regiji Slavonija je prediktor koji, u usporedbi s ostalim regijama, najviše povećava šansu da osoba bude nezaposlena – rezultati pokazuju da u prvoj točki mjerenja život u regiji Slavonija povećava šansu da osoba bude nezaposlena 1,5 puta, u drugoj 1,7 puta, a u trećoj 3,1 puta, u usporedbi s referentnom kategorijom, regijom Zagreb i okolica. Međutim, ovu hipotezu prihvaćamo djelomično, budući da u prvoj točki mjerenja život u regiji Lika i Banovina šansu da osoba bude nezaposlena povećavaju 1,7 puta, dakle nešto više od Slavonije.

Posljednja, peta izvedena hipoteza pretpostavila je da je utjecaj bračnog statusa i suživota s vlastitom malodobnom djecom na šansu da osoba bude nezaposlena relativno nizak. U sve tri točke mjerenja, u odnosu na one koji ne žive s vlastitom malodobnom djecom, osobe koje žive s vlastitom malodobnom djecom imaju 1,3 puta veću šansu da budu u statusu nezaposlene osobe, što možemo smatrati relativno niskim utjecajem. Ipak, neoženjeni i neudate, u usporedbi s onima u braku, imaju 1,7 puta veću šansu da budu nezaposleni u prvoj te 1,8 puta u drugoj i trećoj točki mjerenja, što nije toliko nizak efekt. Stoga ovu hipotezu djelomično prihvaćamo.

U sve tri točke mjerenja, značajni prediktori prilično slabo objašnjavaju kriterijsku varijablu – u prvoj točki mjerenja, model točno svrstava 76,3% ispitanika, što je 1,2% više slučajeva od nul-modela, u drugoj točki je točno svrstanih slučajeva nešto manje - 70,0%, ali je to 4% više u usporedbi s nul-modelom. U trećoj točki, model s prediktorima točno svrstava 2,4% više u usporedbi s nul-modelom, što ukupno iznosi 73,5% slučajeva. Modeli u sve tri točke mjerenja imaju relativno visoku specifičnost - na agregiranim podacima 2008.-2010. zaposleni ispitanici točno su svrstani u 95,1% slučajeva; na podacima 2011.-2013. nešto manje - 88,2%, model na agregiranim podacima 2014.-2016. zaposlene ispitanika točno svrstava u 92,9%. Međutim, osjetljivost – to jest, postotak točno svrstanih nezaposlenih ispitanika mu je relativno niska. To je pogotovo izraženo u prvoj točki mjerenja, kad je model točno svrstao samo 19,9% nezaposlenih ispitanika. U drugoj točki mjerenja točno je

svrstano najviše, 34,6% nezaposlenih ispitanika, dok su u trećoj točki nezaposlenih ispitanici svrstani točno u 25,9% slučajeva.

Moguće razloge za ove razlike možemo potražiti u ukupnom udjelu nezaposlenih kroz promatrane tri točke mjerenja. Zanimljivo je da je ukupna nezaposlenost viša upravo u promatranoj točki u kojoj model pokazuje najvišu osjetljivost. Na tragu toga, ističe kako rast nezaposlenosti nije ravnomjeran među svim sociodemografskim grupama, kao što oporavak, tj. rast ukupne zaposlenosti često može skrivati izostanak porasta nezaposlenosti u ugroženijim grupama (Matković, 2008). To bi moglo biti objašnjenje za to što sociodemografski prediktori u modelu najbolje prepoznaju nezaposlene ispitanike u točki mjerenja u kojoj je nezaposlenost najviša – jer su upravo u toj točki razlike između sociodemografskih grupa najviše izražene, to jest, nezaposlenost se može bolje objasniti sociodemografskim karakteristikama jer je jače zahvatila određene grupe. U ovom slučaju, sudeći prema najvišim iznosima beta koeficijentima, čini se da su najviše pogođene dvije grupe zanimanja – kvalificirani radnici uključujući i bolničke sestre te niskokvalificirani i nekvalificirani radnici kao i osobe nižeg obrazovanja.

7.1. Ograničenja i naputci za daljnja istraživanja

Iako se ovaj rad temelji na analizi podataka dobivenih na reprezentativnom uzorku stanovništva Republike Hrvatske u dobi od 15 do 64 godine te smo utvrdili da se trend porasta u drugoj te ponovnog pada u trećoj točki mjerenja poklapa sa trendom kretanja udjela nezaposlenosti koji je vidljiv iz službenih statistika koji prate indikatore tržišta rada, da bi se ispitanike svrstalo u kategoriju zaposlenih ili nezaposlenih osoba, oni ne moraju zadovoljavati nikakve uvijete, kao što je to predviđeno standardnom definicijom nezaposlenosti koja se koristi u Anketi radne snage (nezaposlena osoba treba zadovoljiti tri uvjeta: 1) nema posao, 2) raspoloživa je krenuti obavljati posao u referentnom periodu i 3) traži posao) niti mora biti evidentirana u Zavod za zapošljavanje – stoga je kao osnovno ograničenje ovog istraživanja to što se njegova kategorizacija na zavisnoj varijabli temelji isključivo na njegovom iskazu.

Pripadnost kategorijama prediktorskih varijabli također ovisi o odgovoru ispitanika, a kao sljedeće ograničenje možemo navesti to što se ispitanici na nekim od varijabli možda nisu sa sigurnošću znali točno svrstati (na primjer, varijabla zanimanje na kojoj je bio najviši postotak odgovora „Ne znam“). Također, varijabla Suživot s vlastitom malodobnom djecom kreirana je iz dvije varijable (s kim žive te ima li u kućanstvu malodobne djece) uz

kontroliranje dobi te trebamo uzeti u obzir da kategoriziranje ispitanika u njoj vjerojatno nije u potpunosti točno.

Za daljnji doprinos proučavanja toga koje karakteristike doprinose većoj šansi bivanja u statusu nezaposlenih osoba, preporučljivo je provesti ove analize na uzorku Ankete radne snage, koja je zbog svoje metodološke strogosti pri kategoriziraju ispitanika u zaposlene i nezaposlene osobe lišena osnovnog ograničenja analize na uzorcima koji se koriste u ovom radu. Također, osim općeg modela koji uključuje ukupni uzorak radno aktivnog stanovništva, zanimljivo bi bilo regresijske analize provesti na sub-uzorcima različitih grupa ispitanika – na primjer, usporedba modela koji objašnjavaju nezaposlenost kod žena s modelima koji objašnjavaju nezaposlenost kod muškaraca ili testiranje modela koji bi objasnili nezaposlenost kod mladih.

8. Zaključak

Na nezaposlenost utječu brojni faktori. U prvom redu, ona ovisi o ukupnoj ekonomskoj razvijenosti zemlje, stanju na tržištu rada, ravnoteži ponude i potražnje poslova. S druge strane, pripadnici pojedinih društvenih skupina, prvenstveno sociodemografskih, nisu međusobno u jednakom riziku da budu u statusu nezaposlene osobe. Pretpostavili smo, a zatim i potvrdili, da se pripadanje kategoriji nezaposlenih osoba može objasniti prediktorskim sklopom koji se sastoji od sociodemografskih varijabli – spol, dob, regija, tip mjesta stanovanja (urbano ili ruralno područje), veličina mjesta stanovanja, obrazovanje, zanimanje, bračni status i suživot sa vlastitom malodobnom djecom, pri čemu su se zanimanja nekvalificiranih i niskokvalificiranih radnika te kvalificiranih radnika uključujući i medicinske sestre, kao i niža razina obrazovanja, pokazali kao karakteristike koje najviše povećavaju šansu da se osoba nađe u statusu nezaposlene osobe.

Ipak, rezultati analize pokazali su da ovaj prediktorski sklop može objasniti tek manji dio rezultata na zavisnoj varijabli, što ostavlja prostor daljnjim istraživanjima na ovu temu i analiziranja drugih prediktora u cilju boljeg razumijevanja koje individualne karakteristike doprinose većoj šansi da osoba bude nezaposlena. U svrhu daljnjih doprinosa istraživanjima na tu temu predlaže se testirati modele na podacima prikupljenim putem Ankete o radnoj snazi, kao i razdvojiti uzorak na sub-uzorke kako bi se provjerilo postoje li razlike u prediktorima između različitih skupina.

9. Literatura

Bilić, N., Jukić, M. (2014) *Pravni vjesnik*, 30 (2): 485 – 505.

Botić, V. (2003) Regionalni aspekti nezaposlenosti u Hrvatskoj. *Privredna kretanja i ekonomska politika*, 5: 27 – 46.

Burgess, P. L. (1994) Unemployment. U *World Book Illustrated Information Finder (CD-ROM Encyclopedia)*. Chicago, US: World Book.

Galić, B. Nikodem, K. Percepcija rodni jednakosti i šansi pri zapošljavanju u hrvatskom društvu. Pogled nezaposlenih žena. *Revija za socijalnu politiku*, 16 (2009), 3; 253-270.

Halmi, A. (2003) *Multivarijatna analiza u društvenim znanostima*. Zagreb: Alinea.

Hussmanns, R., Mehran, F. i Verma, V. (1990.) *Surveys of economically active population, employment, unemployment and underemployment: An ILO manual on concepts and methods*. Geneva: ILO.

Jurić, I. (1980) Prikrivena nezaposlenost u društvenom sektu privrede SR Hrvatske. *Revija za sociologiju*, 10 (3-4): 131—138.

Katić, M. (2006) Kretanja na tržištu rada Hrvatskoj. *Ekonomski misao i praksa*, 15 (1):27-50.

Kerovec, N. (2003) Ne(jednakost) žena na tržištu rada. *Revija za socijalnu politiku*, 10(3-4), 263-282.

Kerovec, N. (1999) Kako mjeriti nezaposlenost. *Revija za socijalnu politiku*. 63/4: 259-267.

Matko, V. (2003) Psihološke posljedice nezaposlenosti i posredujući faktori. U Galešić, M, Maslić-Seršić, D, Šverko, Branimir (ur.). *Psihološki aspekti nezaposlenosti*. Zagreb : Odsjek za psihologiju Filozofskog fakulteta.

Matković, T. (2008) Tko što radi? Dob i rod kao odrednice položaja na tržištu rada u Hrvatskoj. *Revija za socijalnu politiku*, 15 (3): 479 – 502.

Mrnjavac, Ž. (1996) *Mjerenje nezaposlenosti*. Split: Ekonomski fakultet.

Nekić, I. (2003) Socijalne posljedice nezaposlenosti. U Galešić, M, Maslić-Seršić, D, Šverko, Branimir (ur.). *Psihološki aspekti nezaposlenosti*. Zagreb : Odsjek za psihologiju Filozofskog fakulteta.

10.Sažetak

Predikcijski modeli nezaposlenosti: empirijski doprinosi

Sažetak

Ovaj rad kreće od pretpostavke da pripadnici pojedinih društvenih skupina nisu međusobno u jednakom riziku da budu u statusu nezaposlene osobe. U tri točke mjerenja, na agregiranim podacima 2008.-2010., 2011.-2013. i 2014.-2016. koji su prikupljeni unutar istraživanja Omnibus agencije Ipsos, provedbom multivarijatne logističke regresije testirana je hipoteza da se nezaposlenost može objasniti prediktorskim sklopom sastavljenim od sociodemografskih varijabli - spol, dob, regija, tip mjesta stanovanja (urbano ili ruralno područje), veličina mjesta stanovanja, obrazovanje, zanimanje, bračni status i suživot sa vlastitom malodobnom djecom. Hipoteza je potvrđena u sve tri točke mjerenja, međutim, dobiveni modeli relativno slabo objašnjavaju kriterijsku varijablu. Zanimanja nekvalificiranih i niskokvalificiranih radnika te kvalificiranih radnika uključujući i medicinske sestre, kao i niža razina obrazovanja, pokazali su se kao karakteristike koje najviše povećavaju šansu da se osoba nađe u statusu nezaposlene osobe.

Ključne riječi: *binarna logistička regresija, nezaposlenost, radno aktivno stanovništvo, tržište rada*

Predictive models of unemployment: an empirical contribution

Summary

This paper discusses the idea that members of certain social groups aren't at the same risk of unemployment. In three measuring points, on aggregated data between 2008 and 2010, between 2011 and 2013 and between 2014 and 2016 which are collected as a part of the Omnibus research conducted by Ipsos, multivariate logistic regression was applied to test the hypothesis that unemployment can be explained with prediction set made up of sociodemographic variables – gender, age, education, occupation, marital status and cohabitation with their own underage children.

The hypothesis is confirmed in all three measuring points, but obtained models relatively poorly explain the criterion variable. The occupation of unskilled and low skilled workers, as

well as skilled workers, including nurses, and lower level of education, have been shown to be predictors which increase the chances of a person being unemployed the most.

Keywords: *binary logistics regression, unemployment, working-activepopulation, labor market*